



TESIS - KI142502

**PEMBOBOTAN KALIMAT BERDASARKAN
FITUR BERITA, INFORMASI GRAMATIKAL DAN
RELEVANSI KALIMAT TERHADAP JUDUL
UNTUK PERINGKASAN MULTI-DOKUMEN BERITA**

Moch Zawaruddin Abdullah
NRP. 5116201027

DOSEN PEMBIMBING
Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.
NIP. 197512202001122002

PROGRAM MAGISTER
BIDANG KEAHLIAN KOMPUTASI CERDAS DAN VISI
DEPARTEMEN INFORMATIKA
FAKULTAS TEKNOLOGI INFORMASI DAN KOMUNIKASI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018

[Halaman ini sengaja dikosongkan]

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Komputer (M.Kom.)

di

Institut Teknologi Sepuluh Nopember Surabaya

oleh:

Moch Zawaruddin Abdullah

Nrp. 5116201027

Dengan Judul :

PEMBOBOTAN KALIMAT BERDASARKAN FITUR BERITA, INFORMASI
GRAMATIKAL DAN RELEVANSI KALIMAT TERHADAP JUDUL UNTUK
PERINGKASAN MULTI-DOKUMEN BERITA

Tanggal Ujian : 20-07-2018

Periode Wisuda: 2018 Genap

Disetujui oleh :

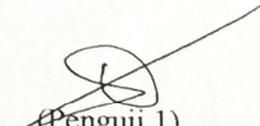
Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

NIP. 197512202001122002


(Pembimbing 1)

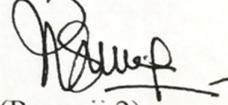
Prof. Dr. Ir. Joko Lianto Buliali

NIP. 196707271992031002


(Penguji 1)

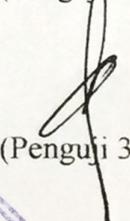
Dr. Eng. Nanik Suciati, S.Kom., M.Kom.

NIP. 197104281994122001


(Penguji 2)

Dr. Eng. Darlis Herumurti, S.Kom., M.Kom.

NIP. 197712172003121001


(Penguji 3)



Dekan FTIK - ITS

Dr. Agus Zainal Arifin, S.Kom., M.Kom.

NIP. 197208091995121001

[Halaman ini sengaja dikosongkan]

**PEMBOBOTAN KALIMAT BERDASARKAN FITUR BERITA,
INFORMASI GRAMATIKAL DAN RELEVANSI KALIMAT
TERHADAP JUDUL UNTUK PERINGKASAN
MULTI-DOKUMEN BERITA**

Nama mahasiswa : Moch Zawaruddin Abdullah

NRP : 5116201027

Pembimbing : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

ABSTRAK

Pembobotan kalimat merupakan tahapan yang sering digunakan dalam peringkasan dokumen, tak terkecuali dokumen berita. Dalam peringkasan dokumen berita, metode pembobotan kalimat untuk menentukan kalimat *representative* sebagian besar menggunakan fitur dari berita itu sendiri seperti *word frequency*, *Term Frequency-Inverse Document Frequency* (TF-IDF), posisi kalimat, dan kemiripan kalimat terhadap judul. Metode ini mampu memilih kalimat *representative* dalam peringkasan dokumen. Akan tetapi metode pembobotan kalimat berdasarkan fitur berita tidak cukup, karena metode dengan fitur tersebut mengabaikan kata informatif dalam kalimat dan hanya mengukur relevansi kalimat dengan judul berdasarkan kesamaan kata.

Penelitian ini bertujuan untuk melakukan peringkasan multi dokumen berita menggunakan metode pembobotan berdasarkan fitur penting berita dengan pendekatan informasi gramatikal (*grammatical information*) dan relevansi kalimat terhadap judul. Informasi gramatikal digunakan untuk mengindikasikan kata informatif dalam suatu kalimat. Sedangkan relevansi kalimat terhadap judul ditujukan untuk mengetahui tingkat keterhubungan kalimat terhadap judul baik dalam konteks kesamaan kata maupun kesamaan makna kata. Pembobotan kalimat berdasarkan kombinasi antara fitur berita dengan informasi gramatikal dan

relevansi kalimat terhadap judul diharapkan mampu memilih kalimat *representative* secara lebih baik dan mampu meningkatkan kualitas hasil ringkasan.

Pada penelitian ini terdapat 4 tahapan yang dilakukan untuk menghasilkan ringkasan multi-dokumen berita antara lain seleksi berita, *text preprocessing*, *sentence scoring*, dan tahap penyusunan ringkasan. Untuk mengukur hasil ringkasan menggunakan metode evaluasi *Recall-Oriented Understudy for Gisting Evaluation* (ROUGE) dengan empat varian fungsi yaitu ROUGE-1, ROUGE-2, ROUGE-L dan ROUGE-SU4. Hasil eksperimen pada 11 kelompok dokumen berita Indonesia pada metode yang diusulkan dibandingkan dengan metode pembobotan dengan pendekatan *trending issue* (NeFTIS). Metode yang diusulkan mencapai hasil yang lebih baik dibandingkan metode NeFTIS dengan peningkatan nilai untuk ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4 secara berturut-turut adalah 58%, 99.32%, 13.53%, 82.65%.

Kata Kunci : peringkasan multi-dokumen, dokumen berita, pembobotan kalimat, informasi gramatikal, relevansi kalimat.

**SENTENCE WEIGHTING BASED ON NEWS FEATURES,
GRAMMATICAL INFORMATION AND SENTENCE
RELEVANCE TO THE TITLE FOR NEWS
MULTI-DOCUMENT SUMMARY**

Student Name : Moch Zawaruddin Abdullah

NRP : 5116201027

Supervisor : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom

ABSTRACT

Sentence weighting is frequent used stages in the document summary. In the news document summary, sentence weighting methods for determining representative sentences mostly used features of the news itself such as word frequency, Term Frequency-Inverse Document Frequency (TF-IDF), sentence position, and resemblance to the title. The methods are adequate for selecting representative sentences in the document summary. However, sentence weighting methods based on news features are not sufficient because it ignores the informative word in the sentence and only measures the relevance of sentence with the title based on the similarity of words.

This research aims to perform multi-document summaries using sentence weighting methods based on news features with grammatical information and the relevance of sentence to the title approach. Grammatical information is used to indicate the informative word in a sentence. The relevance of the sentence to the title is intended to find out the level of connectedness of the sentence to the title both in the context of the similarity of words and similarity of the word meaning. Sentence weighting based on a combination of news features with grammatical information and the relevance of sentence to the title are expected to be able

selecting better representative sentences and improve the quality of the summary results.

In this research, there are 4 stages to obtain news multi-document summary such as news selection, text preprocessing, sentence scoring, and forming summary. Measurement of summary results using Recall-Oriented Understudy for Gisting Evaluation (ROUGE) evaluation method. The results of the experiment on the 11 groups of Indonesian news document are compared with those of the news features with trending issue approach method (NeFTIS). Our proposed method achieved better results with an increasing rate of ROUGE-1, ROUGE-2, ROUGE-L, and ROUGE-SU4 sequently are 58%, 99.32%, 13.53%, 82.65%.

Keywords: *multi-document summaries, news documents, sentence weighting, grammatical information, sentence relevance.*

KATA PENGANTAR

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Puji syukur penulis panjatkan kepada Allah SWT atas rahmat, hidayah dan inayah-Nya, penulis dapat menyelesaikan tesis dalam bentuk buku ini yang berjudul **“Pembobotan Kalimat Berdasarkan Fitur Berita, Informasi Gramatikal, dan Relevansi Kalimat terhadap Judul untuk Peringkasan Multi-dokumen Berita”**. Sholawat dan salam semoga selalu tercurahkan kepada junjungan kami nabi besar Muhammad SAW. Pengerjaan buku ini penulis tujukan untuk mengeksplorasi lebih mendalam mengenai topik *information retrieval*. Selain itu besar harapan penulis bahwa pengerjaan tesis sekaligus pengerjaan buku ini dapat menjadi batu loncatan penulis dalam menimba ilmu yang bermanfaat.

Penulis ingin menyampaikan rasa terima kasih kepada banyak pihak yang telah mendukung, membimbing, menemani dan membantu penulis selama masa pengerjaan tesis maupun masa studi, antara lain:

1. Ibu Dr. Eng. Chastine Fatichah, S.Kom., M.Kom. selaku dosen pembimbing penulis. Ucapan terima kasih juga penulis sampaikan atas segala perhatian, didikan, pengajaran, dan nasihat yang telah diberikan oleh beliau selama masa studi penulis.
2. Bapak Waskitho Wibisono, S.Kom., M.Eng., Ph.D. selaku Ketua Program Magister Teknik Informatika sekaligus dosen wali penulis yang telah memberi dukungan dan arahan dalam menyelesaikan permasalahan akademik.
3. Kepada keluarga penulis, Abah, Ibu, Bapak Ibu mertua serta Istri dan Anak tercinta yang telah memberikan doa, dukungan dan semangat terhadap penulis dalam menyelesaikan studi ini.
4. Kepada Adik kandung dan Adik ipar penulis yang sama-sama dalam menuntut ilmu dan semoga dapat menyelesaikan studi dengan baik.

5. Rekan-rekan mahasiswa pascasarjana angkatan 2016 magister Teknik Informatika yang senantiasa berbagi ilmu pengetahuan dan informasi yang bermanfaat.
6. Pihak-pihak di lingkungan ITS dan semua pihak yang tidak dapat disebutkan semua, yang telah memberikan informasi, motivasi dan saran kepada penulis dalam menyelesaikan studi S2 ini.

Kepada pihak-pihak yang membantu semoga Allah SWT membalas semua kebaikan dengan pahala yang berlimpah. Penulis menyadari bahwa buku ini jauh dari kata sempurna. Maka dari itu, penulis mohon maaf apabila terdapat kesalahan kata maupun makna pada buku ini. Akhir kata, penulis mempersembahkan buku ini sebagai wujud nyata kontribusi penulis dan berharap buku ini dapat memberikan kontribusi ilmiah bagi pengembangan riset dalam ilmu pengetahuan.

Surabaya, 17 Juni 2018

Penulis

DAFTAR ISI

ABSTRAK	v
<i>ABSTRACT</i>	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
BAB 1 PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah	4
1.3. Batasan Masalah	5
1.4. Tujuan	5
1.5. Kontribusi	5
BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI	7
2.1. Peringkasan Dokumen Otomatis	7
2.2. <i>Grammatical Information by Part of Speech Tagging</i>	8
2.3. <i>Sentence Length Threshold</i>	9
2.4. <i>Term Weighting</i>	10
2.4.1. <i>TF-ISF</i>	10
2.4.2. <i>TF-IDF</i>	11
2.5. Posisi Kalimat	12
2.6. <i>N-gram</i>	12
2.7. Relevansi Kalimat Terhadap Judul	13
2.7.1. <i>N-gram Word Similarity</i>	14
2.8. <i>Query Expansion</i>	14
2.8.1. Tesaurus	15
2.8.2. Kateglo	16
BAB 3 METODE PENELITIAN	17

3.1.	Studi Literatur	17
3.2.	Pengumpulan Dataset	18
3.3.	Perancangan Sistem.....	18
3.3.1.	Seleksi Berita.....	19
3.3.2.	<i>Text Preprocessing</i>	19
3.3.3.	Sentences Scoring	22
3.4.	Pembuatan Perangkat Lunak.....	48
3.5.	Uji Coba Sistem	48
3.6.	Metode Evaluasi Hasil Ringkasan.....	49
BAB 4	HASIL DAN PEMBAHASAN.....	53
4.1.	Lingkungan Implementasi	53
4.2.	Dataset Ujicoba	53
4.3.	Dataset <i>Groundtruth</i>	55
4.4.	<i>Training</i> Parameter dan Penentuan Pengambilan Kalimat Representatif .	56
4.5.	Ujicoba dan Analisis Hasil Ringkasan	61
4.4.1.	Ujicoba 1: Analisis Hasil Ringkasan Metode Usulan.....	62
4.4.2.	Ujicoba 2: Perbandingan Performa NeFGISR dengan NeFTIS	67
BAB 5	KESIMPULAN DAN SARAN	73
DAFTAR PUSTAKA	75
BIOGRAFI PENULIS	79

DAFTAR GAMBAR

Gambar 3.1 Tahapan Penelitian	17
Gambar 3.2 Model Desain Sistem.....	18
Gambar 3.3 Desain <i>Text Preprocessing</i>	19
Gambar 3.4 Desain <i>Sentence Scoring</i>	22

[Halaman ini sengaja dikosongkan]

DAFTAR TABEL

Table 2.1 Label <i>POS Tagging</i> untuk Bahasa Indonesia	8
Table 2.2 Contoh rangkaian kata <i>n-gram</i> dengan $n = 4$	13
Tabel 3.1 Contoh rangkaian kata <i>n-gram</i> dengan $n = 3$	21
Tabel 3.2 Contoh isi berita pada dokumen d_1	23
Tabel 3.3 Contoh penghitungan TF.ISF untuk setiap <i>term</i>	24
Tabel 3.4 Bobot kalimat berdasarkan <i>Local Sentence Weighting</i>	25
Tabel 3.5 Contoh Konten Dua Dokumen Berita	26
Tabel 3.6 Contoh penghitungan TF.IDF untuk setiap <i>term</i> pada dokumen d_1 dan d_2	27
Tabel 3.7 Bobot Global Sentence Weighting (W_2) untuk dokumen d_1	29
Tabel 3.8 Bobot Global Sentence Weighting (W_2) untuk dokumen d_2	29
Tabel 3.9 Contoh pembobotan <i>Sentence Position</i> pada dokumen d_1	31
Tabel 3.10 Kelompok label POS Tagging	32
Tabel 3.11 Kalimat hasil POS Tagging untuk Bahasa Indonesia.....	33
Tabel 3.12 Frekuensi <i>term</i> setelah <i>POS Tagging</i>	33
Tabel 3.13 Pembobotan Kalimat berdasarkan <i>POS Tagging Local Distribution</i> .	35
Tabel 3.14 Kalimat hasil POS Tagging untuk Bahasa Indonesia.....	36
Tabel 3.15 Contoh penghitungan TF.IDF untuk setiap <i>term</i> pada dokumen d_1 dan d_2	38
Tabel 3.16 Kalimat hasil POS Tagging untuk Bahasa Indonesia.....	40
Tabel 3.17 Proses pembentukan <i>n-gram</i> dengan $n = 7$ pada dokumen d_1	43
Tabel 3.18 Hasil query expansion untuk judul dokumen	46
Tabel 4.1 Dataset ujicoba.....	53
Tabel 4.2 Dataset <i>groundtruth</i> tiap topik berita	55
Tabel 4.3 Eksperimen penentuan bobot label POS	56
Tabel 4.4 Nilai parameter yang digunakan untuk <i>training</i>	57
Tabel 4.5 Hasil <i>training-1</i> untuk empat topik.....	57
Tabel 4.6 Rata-rata hasil evaluasi ROUGE untuk <i>training-1</i>	58
Tabel 4.7 Hasil <i>training-2</i> untuk empat topik.....	59
Tabel 4.8 Rata-rata hasil evaluasi ROUGE untuk <i>training-2</i>	60

Tabel 4.9 Perbandingan hasil <i>training-1</i> dengan <i>training-2</i>	61
Tabel 4.10 Peningkatan hasil evaluasi <i>training-1</i> terhadap <i>training-2</i>	61
Tabel 4.11 Hasil ujicoba 1 untuk n = 10	62
Tabel 4.12 Sampel Pembobotan Kalimat dengan NeFGISR untuk topik " <i>pilpres</i> "	64
Tabel 4.13 Hasil ringkasan NeFGISR dan <i>groundtruth</i> untuk topik " <i>pilpres</i> "	65
Tabel 4.14 Evaluasi hasil ringkasan dengan 3 varian <i>groundtruth</i> untuk topik " <i>pilpres</i> "	66
Tabel 4.15 Hasil ringkasan NeFGISR dan NeFTIS untuk topik " <i>pilpres</i> "	67
Tabel 4.16 Hasil evaluasi NeFGISR dan NeFTIS terhadap <i>groundtruth-1</i>	68
Tabel 4.17 Hasil evaluasi NeFGISR dan NeFTIS terhadap <i>groundtruth-2</i>	69
Tabel 4.18 Hasil evaluasi NeFGISR dan NeFTIS terhadap <i>groundtruth-3</i>	69
Tabel 4.19 Hasil evaluasi NeFGISR dan NeFTIS terhadap ketiga <i>groundtruth</i> ...	70
Tabel 4.20 Peningkatan hasil evaluasi NeFGISR terhadap NeFTIS untuk topik " <i>pilpres</i> "	70
Tabel 4.21 Jumlah <i>term</i> pada hasil ringkasan untuk topik " <i>pilpres</i> "	70
Tabel 4.22 Jumlah <i>term</i> yang sama antara NeFGISR dan NeFTIS terhadap <i>groundtruth</i> pada topik " <i>pilpres</i> "	71

BAB 1

PENDAHULUAN

1.1. Latar Belakang

Jumlah dokumen digital meningkat secara signifikan pada era teknologi saat ini, tak terkecuali dokumen berita. Banyaknya dokumen berita menimbulkan masalah dalam menggali dan mengolah informasi secara cepat dan akurat. Peringkasan berita menjadi satu solusi untuk menjawab permasalahan dalam penggalian informasi suatu berita. Ringkasan berita dapat diartikan sebagai sebuah teks yang dihasilkan dari satu kalimat atau lebih yang mampu menyampaikan informasi penting dari sebuah berita (Hayatin, Fatichah, & Purwitasari, 2015). Dimana panjang dari sebuah ringkasan tidak lebih dari setengah panjang dokumen asli, dan biasanya lebih pendek (Radev, Hovy, & McKeown, 2002). Akan tetapi dengan jumlah dokumen berita yang besar, tidak memungkinkan untuk pembaca dalam melakukan peringkasan dokumen berita secara cepat dan efisien.

Peringkasan dokumen otomatis (*automatic text summarization*) menjadi salah satu solusi untuk menjawab permasalahan di atas. *Automatic text summarization* adalah proses peringkasan dokumen teks yang dilakukan secara otomatis melalui mesin komputer. Otomatisasi ringkasan dapat dikenakan terhadap satu dokumen (*single document summarization*) atau beberapa dokumen (*multi-document summarization*) (Aditya, Fatichah, & Purwitasari, 2016; Radev et al., 2002). Dimana peringkasan *single* dokumen adalah mengolah dokumen *input* untuk peringkasan dokumen dari satu data sumber. Sedangkan peringkasan multi-dokumen adalah mengolah dokumen *input* untuk peringkasan dokumen dari berbagai dokumen sumber (Wahib, Arifin, & Purwitasari, 2015). Peringkasan multi-dokumen berita merupakan sistem peringkasan yang melibatkan lebih dari satu berita sebagai *input*.

Terdapat dua metode yang digunakan dalam melakukan peringkasan, yaitu *abstractive* dan *extractive*. Peringkasan dokumen secara *abstractive* dilakukan dengan mendapatkan informasi utama yang disampaikan oleh dokumen sumber dan

membentuk peringkasan dengan teknik menyatukan atau menurunkan informasi. Peringkasan dokumen secara *extractive* dilakukan dengan melakukan ekstraksi terhadap kalimat dan mengurutkan berdasarkan nilai paling tinggi dan dijadikan sebagai kandidat ringkasan. Kata-kata dalam peringkasan *extractive* sama persis dengan kata-kata dalam dokumen sumber (Manne, 2012). Hasil ringkasan yang baik harus memiliki cakupan pembahasan (*coverage*) yang luas pada dokumen sumber serta keterhubungan antarkalimat (*coherence*) yang tinggi (Umam, Putro, Qorik, & Pratamasunu, 2015). Selain itu ringkasan harus memiliki sebanyak mungkin konsep-konsep penting (*saliency*) yang ada pada dokumen sumber (Wahib et al., 2015). *Coverage*, *coherence* dan *saliency* dapat menjadi tolak ukur untuk memilih kalimat-kalimat *representative* dalam peringkasan multi-dokumen.

Salah satu tahapan yang sering digunakan dalam peringkasan dokumen otomatis secara *extractive* adalah pembobotan kalimat (*sentence scoring*). Pembobotan kalimat ditujukan untuk menyeleksi kalimat-kalimat penting sebagai dasar penyusunan ringkasan. Kalimat penting yang digunakan sebagai penyusun ringkasan harus mengandung informasi sebanyak mungkin dari dokumen sumber (He, Li, Shao, Chen, & Ma, 2008). Selain itu kalimat dapat menjadi penting jika kata-kata yang menyusun kalimat tersebut juga penting (Wan, Yang, & Xiao, 2007). Pada peringkasan berita, metode pembobotan sebagian besar memanfaatkan fitur dari berita itu sendiri disebut sebagai *News Feature Scoring (NeFS)* (Hayatin et al., 2015).

Penelitian (Radev, Jing, Styś, & Tam, 2004) menggunakan fitur berita (*NeFS*) untuk melakukan pembobotan kalimat, yaitu posisi kalimat, *centroid*, dan kemiripan kalimat terhadap kalimat pertama dari berita. Metode yang diusulkan mampu memberikan hasil yang cukup relevan dalam peringkasan dokumen. Akan tetapi metode tersebut tidak memperhatikan relasi antara judul dengan isi dokumen sehingga pemilihan kalimat untuk peringkasan dokumen kurang koheren (keterpaduan informasi). Penelitian (Ferreira et al., 2013) menggunakan berbagai fitur *NeFS* untuk pembobotan kalimat dalam peringkasan dokumen. Namun tidak semua kombinasi fitur menghasilkan nilai bobot kalimat yang efektif, hanya terdapat beberapa kombinasi metode yang paling efektif dalam melakukan

pembobotan, yaitu *Word Frequency*, *TF-IDF*, Posisi Kalimat, dan kemiripan kalimat terhadap judul (*Resemblance to the Title*).

Selain menggunakan fitur berita, terdapat metode lain untuk menghitung bobot suatu kalimat yaitu dengan memperhitungkan kalimat penting dalam suatu dokumen. Kalimat penting (*sentence important*) didapat apabila dalam kalimat tersebut mengandung kata-kata yang juga penting (Wan et al., 2007). Kata penting adalah kata-kata yang tersebar pada setiap bagian dalam sebuah dokumen (Xia & Chai, 2011). Penelitian (Wahib et al., 2015) mengusulkan pembobotan kalimat untuk memilih kalimat-kalimat yang penting berdasarkan distribusi kalimat. Metode ini mampu meningkatkan bobot kalimat yang memiliki persebaran yang luas pada cluster kalimat. Akan tetapi metode ini mengabaikan *grammatical information* yang dapat mengindikasikan ada atau tidaknya konten informatif dalam sebuah kalimat.

Terdapat cara lain untuk mengoptimalkan tingkat *coverage* pada pembobotan kalimat untuk peringkasan dokumen yaitu dengan memperbaiki *query* atau menambahkan kata kunci yang disebut dengan *query expansion*. *Query expansion* merupakan teknik sebagai penghubung adanya *vocabulary gaps* antar kata kunci (*query*) dan dokumen (Aditya et al., 2016). Kata kunci (*query*) sebagai fitur untuk mengoptimalkan tingkat *coverage* dapat berupa judul berita itu sendiri (Ferreira et al., 2013) atau kata kunci dari sumber lain seperti *trending issue* dari twitter yang membahas mengenai suatu topik berita. Penelitian (Aditya et al., 2016) yang mengajukan metode pembobotan kalimat berita berdasarkan *query expansion* dari *trending issue*. Kemunculan kata kunci yang dihasilkan oleh *trending issue* memiliki relevansi terhadap dokumen berita dengan memperhitungkan *synonym set* hasil *query expansion* dari *trending issue* itu sendiri. *Trending issue* inilah kemudian dijadikan sebagai fitur pada pembobotan kalimat yang dikombinasikan dengan beberapa teknik pembobotan lain yang diambil dari fitur berita, yakni *news Word Frequency*, *TF-IDF* berita, posisi kalimat dari berita.

Selain itu, *grammatical information* pada suatu kalimat juga dapat berpengaruh dalam pembobotan kalimat seperti kelas kata dalam suatu kalimat. Kelas kata yang dimaksud adalah golongan kata dalam satuan bahasa berdasarkan kategori bentuk, fungsi, dan makna dalam sistem gramatikal. Penyusunan kalimat

yang baik dan benar harus berdasarkan pola-pola kalimat baku. Dalam Bahasa Indonesia, kelas kata dibagi menjadi 5 kelompok besar yaitu kata kerja (*verb*), kata sifat (*adjective*), kata keterangan (*adverb*), kata benda (*noun*), dan kata tugas (*function word*) (Pisceldo, Adriani, & Manurung, 2009). Kelas kata yang terkandung dalam *grammatical information* dapat diperoleh dengan menggunakan *Part of Speech Tagging (POS Tagging)*. Terdapat beberapa penelitian yang menggunakan *POS Tagging* dalam pembobotan kalimat, seperti penelitian (Lioma & Blanco, 2009; Meena, 2014), (Manne & Fatima, 2011), dan (Manne, 2012). Penggunaan *POS Tagging* mampu mendefinisikan kelas kata pada suatu kalimat dan menentukan kata mana yang merupakan kata-kata penting. Kata penting memberikan nilai lebih dalam pembobotan kalimat, sehingga proses pemilihan kalimat *representative* untuk peringkasan dokumen lebih efektif.

Berdasarkan informasi dari beberapa penelitian yang telah disebutkan, maka penelitian ini bertujuan untuk melakukan peringkasan multi-dokumen berita dengan mengusulkan metode pembobotan berdasarkan fitur penting berita dengan pendekatan informasi gramatikal (*grammatical information*) dan relevansi kalimat terhadap judul berita. *Grammatical information* ditujukan untuk mengetahui adanya kata informatif pada suatu kalimat yang dapat mengindikasikan bahwa kalimat tersebut penting. Sedangkan relevansi kalimat terhadap judul ditujukan untuk mengetahui adanya tingkat keterhubungan antara kalimat terhadap judul berita, baik hubungan kesamaan konteks kata maupun kesamaan makna (sinonim) kata. Pemilihan kalimat penting dengan skema tersebut diharapkan mampu memilih kalimat *representative* sebagai dasar penyusunan ringkasan dan mampu meningkatkan kualitas hasil ringkasan.

1.2. Perumusan Masalah

Berdasarkan uraian yang telah dijelaskan pada latar belakang, maka beberapa permasalahan yang akan diselesaikan dirumuskan sebagai berikut:

1. Bagaimana melakukan pembobotan kalimat menggunakan metode pembobotan berdasarkan fitur penting berita dengan pendekatan informasi gramatikal (*grammatical information*) dan relevansi kalimat terhadap judul?

2. Bagaimana membangun model *automatic text summarization* berdasarkan pembobotan kalimat yang diusulkan?
3. Bagaimana mengevaluasi hasil ringkasan dokumen berdasarkan pembobotan kalimat yang diusulkan?

1.3. Batasan Masalah

Batasan masalah pada penelitian ini adalah sebagai berikut:

1. Jenis peringkasan dalam penelitian ini adalah *extractive* untuk *input* multi-dokumen berita
2. Dokumen berita menggunakan Bahasa Indonesia
3. Dokumen berita yang akan diproses sudah dikelompokkan sesuai dengan topik berita dan tidak termasuk dalam lingkup penelitian
4. Judul dan isi berita yang akan diproses harus memiliki keterkaitan (relevan).
5. Hasil ringkasan tidak mempertimbangkan urutan atau kesesuaian kalimat untuk kemudahan pembacaan
6. Ringkasan yang dihasilkan berupa kumpulan kalimat, bukan berformat paragraf

1.4. Tujuan

Penelitian ini bertujuan untuk melakukan peringkasan multi-dokumen menggunakan metode pembobotan berdasarkan fitur penting berita dengan mempertimbangkan pendekatan *grammatical information* dan relevansi kalimat terhadap judul, sehingga diharapkan ringkasan dokumen yang dihasilkan dapat lebih baik.

1.5. Kontribusi

Kontribusi dalam penelitian ini adalah untuk melakukan pembobotan kalimat berdasarkan fitur penting berita dengan pendekatan *grammatical information* dan relevansi kalimat terhadap judul untuk peringkasan multi-dokumen. Dimana *grammatical information* dihitung berdasarkan *Part of Speech Tagging (POS Tagging)*, dan relevansi antar kalimat dan judul dihitung berdasarkan kesamaan makna (sinonim) dan kedekatan kata (*n-gram*).

[Halaman ini sengaja dikosongkan]

BAB 2

KAJIAN PUSTAKA DAN DASAR TEORI

2.1. Peringkasan Dokumen Otomatis

Sumber dokumen dalam jumlah besar memberikan dampak negatif bagi pembaca yang mana membutuhkan waktu relatif lama untuk memilah informasi yang sesuai dengan kebutuhan mereka. Ringkasan dibutuhkan untuk mendapatkan isi berdasarkan inti sari bacaan tanpa mengubah informasi penting dari dokumen tersebut. Memahami isi dokumen melalui ringkasan teks dokumen memerlukan waktu yang relatif lebih singkat dibandingkan dengan membaca seluruh isi dokumen, sehingga ringkasan dokumen menjadi sangat penting. Namun demikian, membuat ringkasan manual dengan dokumen yang banyak akan memerlukan waktu dan biaya yang besar, sehingga diperlukan suatu sistem peringkasan secara otomatis untuk mengatasi masalah waktu baca dan biaya.

Automatic text summarization adalah proses peringkasan dokumen teks yang dilakukan secara otomatis melalui mesin computer. Otomatisasi ringkasan dapat dikenakan terhadap satu dokumen (*single document summarization*) atau beberapa dokumen (*multi-document summarization*) (Aditya et al., 2016). Berdasarkan cara membuatnya, terdapat dua fokus dalam peringkasan dokumen, yaitu *generic summary* dan *query driver summary*. *Generic summary* berfokus pada perwakilan dari teks asli yang akan merepresentasikan semua fitur penting dari sebuah dokumen asal. Sedangkan *query driver summary* berfokus pada peringkasan yang bersandar pada spesifikasi kebutuhan informasi dari pemakai (berdasarkan *query user*).

Berdasarkan arah tujuan, peringkasan dapat dibedakan menjadi dua yaitu *abstractive* dan *extractive*. Peringkasan dokumen secara *abstractive* dilakukan dengan mendapatkan informasi utama yang disampaikan oleh dokumen sumber dan membentuk peringkasan dengan teknik menyatukan atau menurunkan informasi. Peringkasan dokumen secara *extractive* dilakukan dengan melakukan ekstraksi

terhadap kalimat dan mengurutkan berdasarkan nilai paling tinggi dan dijadikan sebagai kandidat ringkasan.

Pada penelitian ini peringkasan dokumen dilakukan berdasarkan metode *extractive* dan *generic* dengan mengekstraksi kalimat *representative* dengan multi-dokumen berita sebagai sumber *input*.

2.2. Grammatical Information by Part of Speech Tagging

Part of Speech Tagging (POS-Tag) merupakan suatu proses yang mengidentifikasi informasi gramatikal yaitu kelas kata pada suatu kata dalam kalimat. *Part of Speech Tagging* merupakan bagian dari *Natural Language Processing* dalam menentukan kelas kata (Rashel, Luthfi, Dinakaramani, & Manurung, 2014). Bentuk sederhana dari proses ini adalah identifikasi kata pada sebuah kalimat dan memberikan label kelas kata, baik sebagai kata benda (*noun*), kata kerja (*verb*), kata sifat (*adverb*), dll. Dalam penelitian (Pisceldo et al., 2009) terdapat 25 tag label kelas kata untuk Bahasa Indonesia dengan rincian 9 label untuk *simbol* dan tanda baca, dan 16 label untuk kata seperti pada Tabel 2.1.

Table 2.1 Label *POS Tagging* untuk Bahasa Indonesia

No	Tag	Deskripsi	No	Tag	Deskripsi
1	(Kurung Buka	14	WH	5WH / Kata tanya
2)	Kurung Tutup	15	VB	Kata Kerja
3	,	Koma	16	MD	Modal/Pendandaian
4	.	Titik	17	JJ	Kata Sifat
5	:	Titik Dua	18	CD	Bilangan Pokok
6	--	Tanda Garis	19	NEG	Negasi
7	“	Tanda Kutip Pembuka	20	IN	Kata Depan
8	”	Tanda Kutip Penutup	21	CC	Konjungsi Koordinatif
9	SYM	Simbol	22	SC	Konjungsi Subordinatif
10	NN	Kata Benda Umum	23	RB	Kata Keterangan
11	NNP	Kata Benda Nama Diri	24	WDT	WH-determiners
12	PRP	Kata Ganti Orang	25	FW	Kata Asing
13	PR	Kata Ganti Umum			

Sebagai contoh terdapat kalimat “Saya sedang menulis buku tesis di ruang tamu”, maka hasil dari proses POS-Tag adalah “Saya/PRP sedang/JJ menulis/VB buku/NN tesis/NN di/IN ruang/NN tamu/NN”.

Pada lingkup *text processing*, POS-Tag dapat digunakan dalam *text summarization* untuk proses penentuan kandidat kalimat ringkasan. Seperti penelitian (Lioma & Blanco, 2009) yang menggunakan POS-Tag untuk mengetahui apakah terdapat kata informatif dalam suatu kalimat berdasarkan *grammatical information* yang dibawa oleh POS Tag tersebut.

2.3. *Sentence Length Threshold*

Konsep dari *Sentence Length Threshold* adalah jumlah kata penyusun suatu kalimat harus sekurang-kurangnya sesuai dengan *threshold* (batas ambang) untuk diproses ke suatu sistem. Dalam Bahasa Indonesia, suatu kalimat harus memiliki minimal satu subjek dan satu predikat. Kalimat yang terlalu panjang ataupun terlalu pendek harus dihindari dalam sebuah ringkasan sehingga dibutuhkan batasan (*threshold*) panjang kalimat yang diproses dalam pembobotan kalimat (Meena, 2014; Meena & Gopalani, 2015).

Berdasarkan penelitian (Ferreira et al., 2013), kalimat *representative* yang terlalu panjang atau terlalu pendek tidak dianggap sebagai pemilihan optimal. Metode ini menggunakan perhitungan jumlah kata yang dimiliki kalimat untuk dapat dijadikan kandidat kalimat peringkasan dengan menggunakan persamaan 2.1.

$$Score = Length(s) \times AverageSentenceLength \quad (2.1)$$

Mengadopsi dari metode tersebut, dapat digunakan perhitungan dengan menentukan batas ambang (*threshold*) dari jumlah minimal kata dan jumlah maksimal kata yang terdapat pada kalimat yang dapat dilakukan proses pembobotan kalimat. Dimana kalimat dengan nilai 1 akan diproses pembobotan kalimat, sedangkan kalimat dengan nilai 0 akan diabaikan. Penentuan nilai dapat dihitung dengan menggunakan kondisi seperti persamaan 2.2

$$Score = \begin{cases} 1, & \text{if } (Lmin < Length(s) < Lmax) \\ 0, & \text{otherwise} \end{cases} \quad (2.2)$$

Dimana,

L_{min} : jumlah minimal kata pada kalimat, didefinisikan oleh *user*

L_{max} : jumlah maksimal kata pada kalimat, didefinisikan oleh *user*

2.4. Term Weighting

Term weighting merupakan proses penghitungan bobot tiap *term* yang dicari pada setiap dokumen sehingga dapat diketahui ketersediaan dan kemiripan suatu *term* di dalam dokumen.

2.4.1. TF-ISF

Skema pembobotan *TF-ISF* atau *term frequency – inverse sentence frequency* adalah variasi dari pembobotan *TF-IDF*. *TF-ISF* merupakan fitur yang digunakan pada penelitian (Fachrurrozi, Yusliani, & Yoanita, 2013; Meena & Gopalani, 2015). Dimana *term frequency* (TF) merupakan frekuensi dari kemunculan sebuah *term* pada kalimat yang diproses. Sedangkan *inverse sentence frequency* (ISF) merupakan sebuah perhitungan bagaimana *term* terdistribusi secara menyeluruh pada koleksi kalimat dalam suatu dokumen.

- *Term frequency* (TF)

Merupakan metode yang paling sederhana dalam membobotkan sebuah kata. Setiap kata (*term*) diasumsikan memiliki kepentingan yang proporsional terhadap jumlah kemunculan kata.

$$TF(s, t) = f(s, t) \quad (2.3)$$

- *Inverse sentence frequency* (ISF)

Merupakan metode dalam membobotkan sebuah kata berdasarkan kemunculan kata tersebut pada kumpulan kalimat. *Term* yang jarang muncul pada kumpulan kalimat memiliki nilai yang tinggi

$$ISF(t) = \log\left(1 + \frac{N}{sf(t)}\right) \quad (2.4)$$

Dimana,

N : jumlah total kalimat

$sf(t)$: jumlah kalimat yang terdapat *term* t

Dengan perkalian antara TF dengan ISF dapat menghasilkan pembobotan *term* pada suatu dokumen yang akan digunakan sebagai representasi vector.

$$\begin{aligned} TFISF(s, t) &= TF(s, t) * ISF(t) \\ &= f(s, t) * \log\left(1 + \frac{N}{sf(t)}\right) \end{aligned} \quad (2.5)$$

2.4.2. TF-IDF

Skema pembobotan suatu *term* pada *text mining* secara luas digunakan adalah skema *term frequency – inverse document frequency (TF-IDF)*. *Term frequency* (TF) merupakan frekuensi dari kemunculan sebuah *term* pada dokumen yang diproses. Sedangkan *inverse document frequency* (IDF) merupakan sebuah perhitungan bagaimana *term* terdistribusi secara menyeluruh pada koleksi dokumen yang diproses. IDF menunjukkan hubungan ketersediaan sebuah *term* dalam seluruh dokumen. Semakin sedikit jumlah dokumen yang mengandung *term*, maka nilai IDF semakin besar.

- *Term frequency* (TF)

Merupakan metode yang paling sederhana dalam membobotkan sebuah kata. Setiap kata (*term*) diasumsikan memiliki kepentingan yang proporsional terhadap jumlah kemunculan kata pada dokumen.

$$TF(d, t) = f(d, t) \quad (2.6)$$

- *Inverse document frequency* (IDF)

Merupakan metode dalam membobotkan sebuah kata berdasarkan kemunculan kata tersebut pada kumpulan dokumen. *Term* yang jarang muncul pada kumpulan dokumen memiliki nilai yang tinggi

$$IDF(t) = \log\left(1 + \frac{N}{df(t)}\right) \quad (2.7)$$

Dimana,

N : jumlah total dokumen

$df(t)$: jumlah dokumen yang terdapat *term* t

Dengan perkalian antara TF dengan IDF dapat menghasilkan pembobotan *term* pada suatu dokumen yang akan digunakan sebagai representasi vector.

$$\begin{aligned}
 TFIDF(d, t) &= TF(d, t) * IDF(t) \\
 &= f(d, t) * \log\left(1 + \frac{N}{df(t)}\right)
 \end{aligned}
 \tag{2.8}$$

2.5. Posisi Kalimat

Posisi kalimat merupakan salah satu fitur berita yang dapat digunakan untuk pembobotan kalimat. Dimana penilaiannya berdasarkan pada letak kalimat dalam sebuah dokumen. Sama seperti penelitian (Ferreira et al., 2013; Hayatin et al., 2015) yang menggunakan posisi sebagai salah satu fitur pembobotan kalimat. Dengan menggunakan aturan, kalimat yang posisinya berada di awal dokumen memiliki skor lebih besar dibanding kalimat yang posisinya di akhir. Penelitian tersebut mampu memberikan penjelasan ilmiah tentang alasan penggunaan aturan tersebut untuk pembobotan kalimat dengan mengutip pernyataan dari Baxendale bahwa kebanyakan kalimat yang muncul di awal paragraf merupakan *topic sentence*. Hal inilah yang menjadi dasar (Mei & Chen, 2012) dalam penelitiannya untuk memberikan skor lebih besar pada kalimat yang muncul di awal dokumen. Penelitian ini meyakini bahwa alasan ini merupakan alasan yang tepat untuk memberikan skor lebih besar pada kalimat yang ada di posisi awal dibanding dengan penggunaan alasan *topic sentence*.

2.6. N-gram

Menurut (Jurafsky & Martin, 2014), *N-gram* adalah model sederhana yang memberikan probabilitas pada kalimat dan rangkaian kata. *N-gram* merupakan rangkaian dari N kata penyusun.

- 1-gram (unigram): rangkaian kata yang terdiri dari 1 kata
- 2-gram (bigram): rangkaian kata yang terdiri dari 2 kata
- 3-gram (trigram): rangkaian kata yang terdiri dari 3 kata
- *N-gram (n-gram)*: rangkaian kata yang terdiri dari n kata

Total n rangkaian kata yang dapat dibentuk dari suatu kalimat adalah seperti persamaan 2.9

$$N = Length(s) - 1 \tag{2.9}$$

Dimana,

N = total n gram yang dapat dilakukan

$Length(s)$ = jumlah total kata penyusun kalimat

Sebagai contoh terdapat kalimat “Saya sedang menulis buku tesis”. Terdapat 5 kata penyusun sehingga nilai N adalah 4. Hasil dari n -gram dapat dilihat pada Tabel 2.2.

Table 2.2 Contoh rangkaian kata n -gram dengan $n = 4$

N	Hasil
1 (<i>unigram</i>)	“Saya”, “sedang”, “menulis”, “buku”, “tesis”
2 (<i>bigram</i>)	“Saya sedang”, “sedang menulis”, “menulis buku”, “buku tesis”
3 (<i>trigram</i>)	“Saya sedang menulis”, “sedang menulis buku”, “menulis buku tesis”
4 (<i>quadgram</i>)	“Saya sedang menulis buku”, “sedang menulis buku tesis”

2.7. Relevansi Kalimat Terhadap Judul

Judul merupakan satu komponen penting dalam mendeskripsikan konten suatu dokumen secara ringkas dan jelas. Sebuah judul minimal mengandung unsur SP-O-K (Subyek – Predikat – Obyek – Keterangan) dan dapat diambil dari beberapa kata atau kutipan yang ada dalam isi dokumen. Hal inilah yang menjadi dasar penggunaan judul sebagai informasi untuk mengetahui kalimat penting dalam sebuah dokumen (Verdianto, Arifin, & Purwitasari, 2016).

Konsep dari teknik pembobotan kalimat berdasarkan kemiripan kalimat terhadap judul adalah bahwa bobot sebuah kalimat besar ketika nilai kemiripan antara judul dengan kalimat tinggi. Semakin besar bobot kalimat maka kalimat tersebut akan dianggap semakin penting. Kalimat yang mirip dengan judul dan kalimat yang mencakup kata-kata dalam judul yang akan dianggap sebagai kalimat penting (Ferreira et al., 2013).

Konsep relevansi kalimat terhadap judul mencakup tingkat kemiripan kalimat terhadap judul maupun tingkat kemiripan kalimat terhadap kesamaan arti dari judul. Proses pembobotan kalimat dengan menggunakan tingkat kemiripan kalimat terhadap judul banyak dilakukan oleh para peneliti, seperti penelitian (Aditya et al., 2016; Ferreira et al., 2013; Hayatin et al., 2015; Verdianto et al., 2016). Dimana

proses pembobotan kalimat berdasarkan perhitungan antara jumlah *term* judul yang muncul pada kalimat dibagi dengan jumlah seluruh *term* yang ada pada judul

$$Score(s) = \frac{NTW}{T} \quad (2.10)$$

Dimana,

NTW : jumlah kata pada kalimat yang mirip dengan kata pada judul

T : jumlah kata yang ada pada judul

2.7.1. *N-gram Word Similarity*

Konsep dari *N-gram Word Similarity (NWS)* adalah proses penghitungan kemiripan kalimat berdasarkan *n-gram* (pembahasan 2.5). Dimana proses pembobotan berdasarkan tingkat kemiripan antara dua kalimat. Semakin mirip rangkaian kata antara dua kalimat, semakin tinggi bobotnya. Dari persamaan 2.10 dapat diketahui bahwa persamaan tersebut sama dengan NTW , akan tetapi hanya pada perhitungan di $n = 1$ (*unigram*). Mengadopsi dari persamaan 2.10, dapat dijabarkan fungsi untuk menghitung kemiripan berdasarkan *n-gram* seperti persamaan 2.11

$$Score(S_i) = \frac{\sum_{w=1}^n \left(\frac{NTW_w}{T_w} \right)}{n}, \quad n = \min(\text{length}(S_i), \text{length}(\text{title})) \quad (2.11)$$

Dimana,

NTW_w : jumlah rangkaian kata pada kalimat S_i yang mirip dengan rangkaian kata pada judul pada w level rangkaian

T_w : Jumlah rangkaian kata pada judul pada w level rangkaian

n : nilai minimum dari panjang kalimat antara judul dengan kalimat S_i .

2.8. *Query Expansion*

Query Expansion merupakan proses perumusan ulang *query input* dengan memberikan tambahan pada beberapa kata atau frasa sebagai perluasan *query input*. *Query expansion* ditujukan untuk meningkatkan performa dalam proses *information retrieval* dan diharapkan mampu menangani masalah ketidakjelasan *query*

(*disambiguate query*) (Aditya et al., 2016). Beberapa *web search engine* menggunakan *query expansion* untuk menyediakan *query alternative* atau perluasan *query* pencarian untuk *user*. Bentuk *query expansion* yang paling umum adalah analisis *global*, dengan menggunakan beberapa bentuk tesaurus. Penggunaan *query expansion* secara umum meningkatkan *recall* dan banyak digunakan dalam bidang sains dan teknik.

2.8.1. Tesaurus

Tesaurus adalah kamus kata-kata dan ungkapan yang dikumpulkan menurut kesamaan artinya dan sinonimnya. Berasal dari bahasa Yunani yaitu “*Thesaurus* yang artinya kekayaan, harta ataupun gudang tempat menyimpan harta benda atau kekayaan”. (Sri Rohyanti Z.: 2002: 1). Tesaurus sering *termasuk* kata terkait yang memiliki hal yang hampir sama. Beberapa tesaurus juga *termasuk* daftar hiponim (sub-bagian, misalnya "mawar" adalah hiponim dari bunga) yang sering digunakan, serta antonim (dua kata yang memiliki arti berlawanan). Tesaurus dapat didefinisikan dalam dua pengertian yaitu menurut fungsi dan strukturnya

1. Menurut fungsinya.

Thesaurus dalam daftar istilah untuk mengawasi kosa kata yang dipakai untuk menterjemahkan bahasa sehari-hari (bahasa alami) dari dokumen, pengindeks atau pemakai ke dalam bahasa sistem (bahasa dokumentasi, bahasa informasi).

2. Menurut strukturnya.

Thesaurus adalah daftar kata-kata yang dinamis dan terkendali yang berhubungan satu sama lain secara semantik, dan secara umum mencakup bidang ilmu pengetahuan tertentu.

Tesaurus merupakan himpunan kata-kata terkendali yang berhubungan satu sama lain secara semantik dan hierarkis, yang dapat dipergunakan untuk menterjemahkan bahasa sehari-hari ke dalam bahasa indeks dalam bidang ilmu pengetahuan tertentu. Thesaurus dipergunakan secara luas untuk mengendalikan kosa kata (*vocabulary control*) dalam sistem terkoordinasi, kemudian menggunakan sistem komputerisasi dan sistem “Pre –coordinate”.

Tesaurus dapat berfungsi sebagai sistem untuk mengolah informasi dan sarana temu kembali informasi yang berbasis komputer. Sebagai sistem pengelolaan informasi, tesaurus dapat berfungsi sebagai pedoman dalam mengolah dokumen seperti pembuatan indeks dan penentuan tajuk. Sebagai sarana temu kembali informasi, thesaurus terdiri dari komponen-komponen pokok yang dapat digunakan dalam sistem temu kembali informasi seperti struktur kosa kata kendali dan sistem acuan.

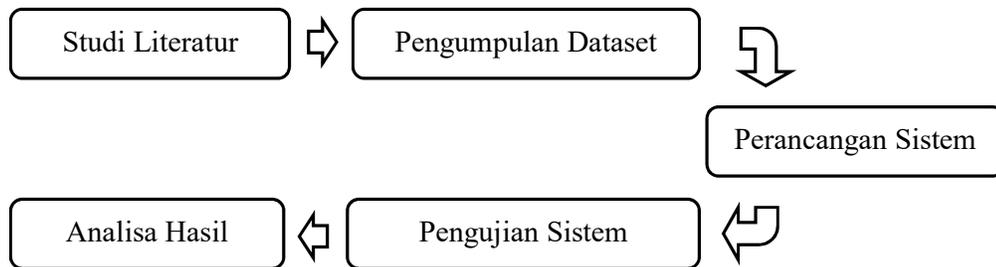
2.8.2. Kateglo

Kateglo adalah layanan website yang terbuka untuk umum dan berisi kamus, tesaurus, dan glosarium bahasa Indonesia. Kateglo beralamatkan www.kateglo.com dan memiliki lisensi CCBY-NC-SA yang secara ringkas seluruh isi dapat disalin, disebar, dan diadaptasi dengan bebas dengan persyaratan mencantumkan sumber isi, tidak untuk tujuan komersial, dan dalam lisensi yang sama atau serupa dengan lisensi CC-BY-NC-SA. Data kamus kata pada kateglo ber sumber dari Pusat Bahasa Departemen Pendidikan Nasional. Kateglo menyediakan daftar padanan istilah suatu bidang ilmu tertentu sekaligus tautan ke Wikipedia mengenai penjelasan istilah tersebut.

BAB 3

METODE PENELITIAN

Dalam Bab 3 ini berisi pembahasan mengenai metode penelitian yang memuat tahapan penelitian. Tahapan dari penelitian yang diusulkan dibagi menjadi lima tahap, yakni: studi literatur, pengumpulan dataset, perancangan sistem, pengujian sistem, dan analisa hasil seperti yang ditunjukkan Gambar 3.1.



Gambar 3.1 Tahapan Penelitian

3.1. Studi Literatur

Tahap pertama dari metode penelitian ini adalah studi literature. Studi literatur dilakukan untuk menggali informasi dan menganalisa perkembangan metodologi yang menjadi sumber referensi bagi penelitian ini. Sumber referensi yang digunakan berasal dari artikel jurnal, *conference*, dan buku. Studi literature bertujuan untuk pemahaman teori dan pematangan konsep sebagai informasi penunjang dalam melakukan penelitian yang diusulkan. Beberapa referensi yang dibutuhkan berkaitan dengan penelitian ini adalah:

1. *Text Preprocessing : sentences segmentation, tokenizing, stopword, stemming*
2. *Grammatical Information: POS Tagging*
3. *N-gram*
4. *Query expansion*
5. *Sentences scoring*

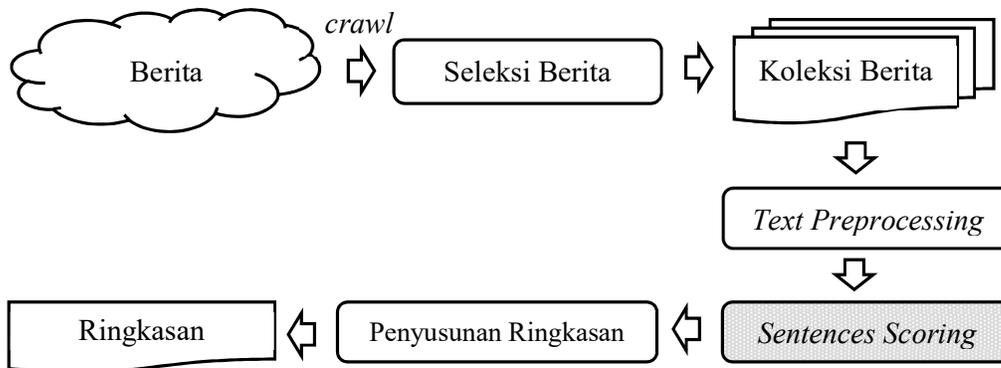
3.2. Pengumpulan Dataset

Tahapan Pengumpulan Dataset dilakukan untuk mengumpulkan data-data yang akan dijadikan data ujicoba dan analisa dari penelitian yang dilakukan. Kumpulan berita diambil secara manual dari website berita seperti detik.com, jawapos.com, republika.com, dan kompas.com. Data berita yang didapat akan disimpan dalam format xml. Format penulisan xml untuk berita dapat dijabarkan sebagai berikut:

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<artikel xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance">
  <id>Nomor Id Berita</id>
  <topik>Topik Berita</topik>
  <judul>Judul Berita</judul>
  <tanggal>Tanggal berita</tanggal>
  <isi>Isi konten berita</isi>
  <link>Link Berita</link>
</artikel>
```

3.3. Perancangan Sistem

Secara garis besar ada empat proses yang dilakukan pada perancangan sistem. Empat tahapan proses tersebut adalah seleksi berita, *text preprocessing*, *sentence scoring*, dan penyusunan ringkasan. Gambaran perancangan sistem dapat dilihat pada gambar 3.2. Adapun penjelasan tiap proses dijelaskan pada subbab berikutnya



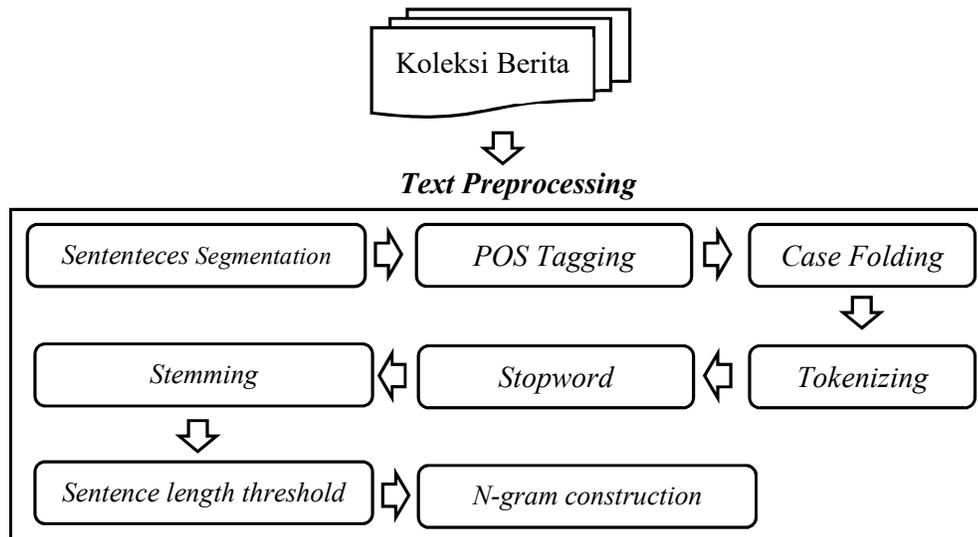
Gambar 3.2 Model Desain Sistem

3.3.1. Seleksi Berita

Tahapan seleksi berita ini dilakukan untuk mengelompokkan berita berdasarkan kategori dan tiap kategori berita memiliki beberapa topik berita. Data berita yang akan diproses terlebih dahulu akan diseleksi berdasarkan topik berita dan tiap topik berita berisi beberapa dokumen berita.

3.3.2. Text Preprocessing

Fase *Text preprocessing* adalah fase yang dilakukan untuk mengolah dokumen berita menjadi token/*term* untuk dijadikan *input* dalam proses pembobotan kalimat. Proses *text preprocessing* dilakukan terhadap isi dokumen berita maupun judul berita.



Gambar 3.3 Desain *Text Preprocessing*

Pada penelitian ini terdapat tujuh tahapan dalam fase *text preprocessing* seperti yang ada pada Gambar 3.3, yaitu tahapan

a. *Sentences segmentation*

Sentences segmentation adalah proses pemenggalan teks dokumen menjadi kumpulan kalimat. Pemilihan kalimat *representative* untuk peringkasan multi-dokumen berita tidak luput dari segmentasi kalimat (*sentences segmentation*) yang diambil dari dokumen. Proses segmentasi kalimat sangat penting sehubungan dengan proses pembobotan kalimat. Kesalahan

dalam segmentasi kalimat dapat mengakibatkan kesalahan dalam menentukan kalimat *representative* sehingga hasil peringkasan tidak sesuai. Seperti contoh “Saya adalah seorang mahasiswa ITS. Saya kuliah di Jurusan Teknik Informatika. Saya tinggal di Jl. Manyar Sabrangan No. 9 Blok IX Surabaya.”. Dari teks tersebut akan diperoleh tiga kalimat dari sentence segmentation, yaitu “Saya adalah seorang mahasiswa ITS”, “Saya kuliah di Jurusan Teknik Informatika”, dan “Saya tinggal di Jl. Manyar Sabrangan No. 9 Blok IX Surabaya”. Segmentasi kalimat yang baik mampu memilah kalimat dalam suatu teks secara benar dan terstruktur sehingga pemilihan kalimat menjadi utuh dan dapat meningkatkan proses pemilihan kalimat *representative* untuk peringkasan dokumen. Dalam hal ini proses *sentence segmentation* menggunakan *library sastrawi sentence-detector for Bahasa Indonesia*. Library ini mampu melakukan segmentasi kalimat dengan benar dan utuh.

b. *POS Tagging*

POS Tagging atau *Part of Speech Tagging* adalah proses untuk mengidentifikasi kelas kata yang ada dalam suatu kalimat. Dalam proses mengidentifikasi kelas kata, sistem menggunakan *application program interface* (API) dari *Part of Speech* khusus Bahasa Indonesia yang beralamat di <http://bahasa.cs.ui.ac.id/postag/tagger>.

c. *Case Folding*

Case Folding adalah proses konversi seluruh karakter huruf pada suatu teks atau kalimat menjadi bentuk format yang sama (menjadi huruf capital atau huruf kecil). Dalam hal ini *case folding* yang diterapkan adalah dengan menjadikan karakter huruf berformat huruf kecil (*lowercase*).

d. *Tokenizing*

Tokenizing adalah proses pemenggalan teks atau kalimat menjadi unit-unit kecil pembentuk kalimat yaitu *term/kata*.

e. *Stopword*

Stopword adalah proses filtrasi kata-kata umum (*common words*) yang biasanya muncul dalam frekuensi besar dan dianggap tidak memiliki makna dalam suatu kalimat.

f. *Stemming*

Stemming dilakukan untuk merubah kata bentukan menjadi kata dasar, seperti contoh kata “*memakan*” menjadi “*makan*”, “*berjalan*” menjadi “*jalan*”.

g. *Sentences length threshold*

Sentences length threshold adalah proses filtrasi terhadap kalimat yang akan diproses apabila kalimat memiliki batas ambang (*threshold*), baik pada batas ambang jumlah kata minimal maupun batas ambang jumlah kata maksimal. Kalimat yang kurang dari ambang minimal atau kalimat yang lebih dari ambang maksimal akan diabaikan dari proses pembobotan kalimat. Hal ini ditujukan untuk optimasi pemilihan kalimat agar kalimat *representative* yang menjadi kalimat ringkasan tidak terlalu pendek atau kalimat tidak terlalu panjang.

h. *N-gram construction*

N-gram construction adalah proses penggabungan kata pada suatu kalimat menjadi *n* rangkaian kata dimana nilai maksimal *n* adalah (total kata pada kalimat) – 1. Contoh terdapat 4 kata penyusun sebuah kalimat yaitu “Saya suka makan pisang”. Maka akan menghasilkan nilai $n = 3$ untuk *n-gram construction*. Hasil *n-gram construction* dapat dilihat seperti Tabel 3.1 berikut

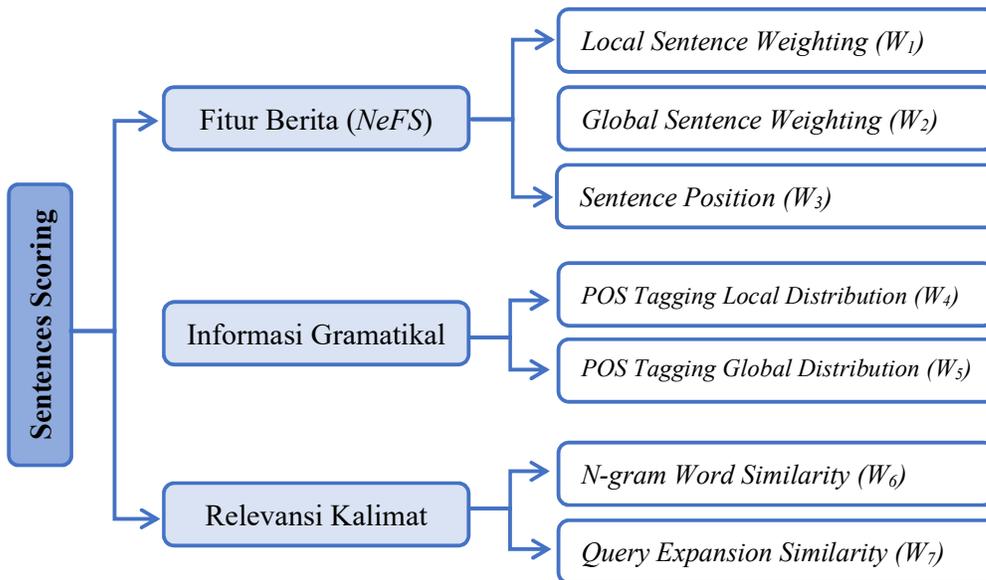
Tabel 3.1 Contoh rangkaian kata *n-gram* dengan $n = 3$

N	Hasil
1 (<i>unigram</i>)	“Saya”, “suka”, “makan”, “pisang”
2 (<i>bigram</i>)	“saya suka”, “suka makan”, “makan pisang”
3 (<i>trigram</i>)	“saya suka makan”, “suka makan pisang”

N-gram construction diaplikasikan terhadap kalimat dan judul yang digunakan untuk proses pembobotan kalimat berdasarkan tingkat relevansi kalimat terhadap judul. Semakin banyak rangkaian kata yang sama dan semakin besar nilai *n* pada kalimat terhadap judul, maka tingkat relevansi kalimat terhadap judul semakin tinggi.

3.3.3. Sentences Scoring

Fase *sentences scoring* adalah tahapan proses pembobotan kalimat yang dilakukan untuk menentukan kalimat *representative* sebagai kalimat penyusun ringkasan. Terdapat tiga komponen utama dalam *sentences scoring* yaitu fitur berita (*News Feature Scoring / NeFS*), *grammatical information*, dan relevansi kalimat terhadap judul. Dalam tiap komponen utama terdapat sub-komponen yang digunakan untuk pembobotan kalimat yaitu *Local sentence weighting*, *global sentence weighting*, *sentence position*, *Part of Speech Tagging (POS Tagging)*, *N-gram word similarity*, dan *Query Expansion Similarity*. Untuk lebih jelasnya dapat dilihat seperti Gambar 3.4 berikut.



Gambar 3.4 Desain *Sentence Scoring*

Berdasarkan Gambar 3.4 di atas, pada komponen Fitur Berita (*News Feature Scoring / NeFS*), terdapat tiga sub-komponen dalam melakukan pembobotan kalimat yaitu *Local Sentence Weighting* (W_1), *Global Sentence Weighting* (W_2), dan *Sentence Position* (W_3). Pada komponen Informasi Gramatikal terdapat dua sub-komponen yaitu *POS Tagging Local Distribution* (W_4), dan *POS Tagging Global Distribution* (W_5). Sedangkan untuk komponen terakhir Relevansi Kalimat, terdapat dua sub-komponen yaitu *N-gram Word Similarity* (W_6), dan *Query*

Expansion Similarity (W_7). Ketujuh sub-komponen (W_1 - W_7) inilah yang akan dilakukan untuk melakukan pembobotan kalimat. Untuk penjelasan sub-komponen W_1 - W_7 dapat dijabarkan seperti berikut:

3.3.3.1. *Local Sentence Weighting* (W_1)

Local sentence weighting merupakan pembobotan kalimat yang ditujukan untuk memberikan bobot kalimat terhadap dokumen tunggal, dimana kalimat yang memiliki bobot paling tinggi merupakan kalimat *representative* yang mewakili konten dalam satu dokumen. Pembobotan kalimat ini menggunakan pendekatan *term frequency – inverse sentence frequency* (*TF-ISF*) yang sudah dijabarkan pada pembahasan 2.4.1. Setelah didapatkan bobot tiap *term* pada dokumen dengan menggunakan persamaan 2.5, pembobotan kalimat pertama (W_1) dilakukan dengan menghitung jumlah bobot *term* j yang muncul pada kalimat i (S_i).

$$W_1(S_i) = \log \left(1 + \frac{\sum_{j=1}^k TF.ISF_{ij}}{k} \right) \quad (3.1)$$

Dimana,

k : jumlah total *term* pada kalimat i (S_i)

Contoh, dalam dokumen berita d_1 yang berjudul “Ketua KPK Heran DPR Mempermasalahkan Penindakan KPK.” terdapat konten berita seperti Tabel 3.2.

Tabel 3.2 Contoh isi berita pada dokumen d_1

No	Kalimat
1	Komisi III DPR menggelar Rapat Dengar Pendapat dengan KPK hari ini.
2	Masalah yang paling dibahas adalah masalah Operasi Tangkap Tangan para kepala daerah.
3	Ketua KPK, Agus Rahardjo merasa heran kenapa DPR malah mempermasalahkan proses penindakan KPK selama ini, ketimbang proses pencegahan korupsi.
4	Padahal menurut Agus, sebagian besar anggaran KPK digunakan untuk melakukan pencegahan dan menindak para pelaku korupsi.
5	Menurutnya, DPR sudah sepatutnya fokus mengawasi proses yang dilakukan KPK dalam mencegah tindak pidana korupsi.

Dari contoh dokumen berita di atas dapat diketahui bahwa total kalimat isi berita sebanyak 5 kalimat dan akan diproses pada tahapan *text preprocessing*. Proses penghitungan pada pembobotan kalimat W_i hanya menggunakan kalimat konten (isi berita) pada perhitungannya dan mengabaikan kalimat judul. Untuk lebih jelasnya bisa mengacu pada Tabel 3.3.

Tabel 3.3 Contoh penghitungan TF.ISF untuk setiap *term*

<i>Term</i>	<i>TF</i>	<i>sf(t)</i>	<i>ISF</i>	<i>TF.ISF</i>
agus	2	2	0.544	1.088
anggar	1	1	0.778	0.778
awas	1	1	0.778	0.778
bagi	1	1	0.778	0.778
bahas	1	1	0.778	0.778
cegah	3	3	0.426	1.278
daerah	1	1	0.778	0.778
dapat	1	1	0.778	0.778
dengar	1	1	0.778	0.778
dpr	3	3	0.426	1.278
fokus	1	1	0.778	0.778
gelar	1	1	0.778	0.778
guna	1	1	0.778	0.778
hari	1	1	0.778	0.778
heran	1	1	0.778	0.778
iii	1	1	0.778	0.778
kenapa	1	1	0.778	0.778
kepala	1	1	0.778	0.778
ketimbang	1	1	0.778	0.778
ketua	1	1	0.778	0.778
komisi	1	1	0.778	0.778
korupsi	3	3	0.426	1.278
kpk	5	4	0.352	1.76
laku	3	2	0.544	1.632
lama	1	1	0.778	0.778
masalah	3	2	0.544	1.632
operasi	1	1	0.778	0.778
padahal	1	1	0.778	0.778
para	2	2	0.544	1.088
patut	1	1	0.778	0.778
pidana	1	1	0.778	0.778

proses	3	2	0.544	1.632
rahardjo	1	1	0.778	0.778
rapat	1	1	0.778	0.778
rasa	1	1	0.778	0.778
tangan	1	1	0.778	0.778
tangkap	1	1	0.778	0.778
tindak	3	3	0.426	1.278
turut	2	2	0.544	1.088

Dari proses penghitungan TF.ISF yang ditunjukkan Tabel 3.3 dapat diperoleh bobot kalimat berdasarkan *Local Sentence Weighting* (W_1) adalah seperti Tabel 3.4 berikut.

Tabel 3.4 Bobot kalimat berdasarkan *Local Sentence Weighting*

S_i	$TF.ISF$	W_1
1	$\log(1 + ((0.778 + 0.778 + 1.278 + 0.778 + 0.778 + 0.778 + 0.778 + 1.76 + 0.778) / 9))$	0.28839
2	$\log(1 + (1.632 + 0.778 + 1.632 + 0.778 + 0.778 + 0.778 + 1.088 + 0.778 + 0.778) / 9))$	0.30151
3	$\log(1 + (0.778 + 1.76 + 1.088 + 0.778 + 0.778 + 0.778 + 0.778 + 1.278 + 1.632 + 1.632 + 1.278 + 1.76 + 0.778 + 0.778 + 1.632 + 1.278 + 1.278) / 17))$	0.33847
4	$\log(1 + (0.778 + 1.088 + 1.088 + 0.778 + 0.778 + 1.76 + 0.778 + 1.632 + 1.278 + 1.278 + 1.088 + 1.632 + 1.278) / 13))$	0.33682
5	$\log(1 + (1.088 + 1.278 + 0.778 + 0.778 + 0.778 + 1.632 + 1.632 + 1.76 + 1.278 + 1.278 + 0.778 + 1.278) / 12))$	0.34136

3.3.3.2. *Global Sentence Weighting* (W_2)

Global sentence weighting merupakan pembobotan kalimat yang ditujukan untuk memberikat bobot kalimat terhadap kata yang muncul pada beberapa dokumen. Kata yang sama dan tersebar pada beberapa dokumen, mengindikasikan kata tersebut penting dan merepresentasikan tingkat similaritas dokumen. Kata penting pada kalimat tersebut dapat mewakili sebagian dokumen dalam menentukan kalimat *representative* untuk peringkasan dokumen.

Pembobotan kalimat kedua ini (W_2) menggunakan pendekatan *term frequency – inverse document frequency (TF-IDF)* yang sudah dijabarkan pada pembahasan 2.4.2. Setelah didapatkan bobot tiap *term* pada dokumen dengan menggunakan persamaan 2.8, pembobotan kalimat W_2 dilakukan dengan menghitung jumlah bobot *term j* yang muncul pada kalimat i (S_i) seperti persamaan 3.2

$$W_2(S_i) = \log \left(1 + \frac{\sum_{j=1}^k TF.IDF_{ij}}{k} \right) \quad (3.2)$$

Dimana,

k : jumlah total *term* pada kalimat i (S_i)

Contoh penghitungan *global sentence weighting (W₂)* pada dua dokumen, yaitu dokumen d_1 yang berjudul “Ketua KPK Heran DPR Mempermasalahkan Penindakan KPK.” dan dokumen d_2 dengan judul “KPK Heran, DPR Selalu Mempermasalahkan Penyadapan”. Isi berita dari kedua dokumen contoh dapat dilihat seperti Tabel 3.5.

Tabel 3.5 Contoh Konten Dua Dokumen Berita

Dokumen	Kalimat
d_1	<ol style="list-style-type: none"> 1. Komisi III DPR menggelar Rapat Dengar Pendapat dengan KPK hari ini. 2. Masalah yang paling dibahas adalah masalah Operasi Tangkap Tangan para kepala daerah. 3. Ketua KPK, Agus Rahardjo merasa heran kenapa DPR malah mempermasalahkan proses penindakan KPK selama ini, ketimbang proses pencegahan korupsi. 4. Padahal menurut Agus, sebagian besar anggaran KPK digunakan untuk melakukan pencegahan dan menindak para pelaku korupsi. 5. Menurutnya, DPR sudah sepatutnya fokus mengawasi proses yang dilakukan KPK dalam mencegah tindak pidana korupsi.

-
1. Wakil Ketua KPK, Laode mengaku heran dengan sikap DPR dalam hal ini adalah Komisi III, kerap memperlakukan penyadapan yang dilakukan oleh pihaknya.
 2. Padahal semua aparat hukum di Indonesia, baik itu Kepolisian, dan Jaksa memiliki kewenangan untuk melakukan penyadapan dalam bekerja.
- d2*
3. "Saya kurang paham, kenapa penyadapan di KPK selalu dipermasalahkan, padahal semua penegak hukum di Indonesia mempunyai kewenangan itu (penyadapan)," ujar Laode.
 4. Menurut Laode, selama ini KPK melakukan penyadapan sudah sesuai dengan undang-undang yang ada.
 5. Bahkan sudah diputuskan oleh Mahkamah konstitusi, bahwa tidak bertentangan dengan konstitusi.
-

Dari contoh dua dokumen berita pada Tabel 3.5 yang telah ditunjukkan, proses penghitungan pada pembobotan kalimat W_2 hanya menggunakan kalimat konten (isi berita) dan mengabaikan kalimat judul. Untuk lebih jelasnya bisa mengacu pada Tabel 3.6.

Tabel 3.6 Contoh penghitungan TF.IDF untuk setiap *term* pada dokumen d_1 dan d_2

Term	TF	df(t)	IDF	TF.IDF
agus	2	1	0.477	0.954
aku	1	1	0.477	0.477
anggar	1	1	0.477	0.477
aparat	1	1	0.477	0.477
awas	1	1	0.477	0.477
bagi	1	1	0.477	0.477
bahas	1	1	0.477	0.477
baik	1	1	0.477	0.477
cegah	3	1	0.477	1.431
daerah	1	1	0.477	0.477
dapat	1	1	0.477	0.477
dengar	1	1	0.477	0.477
dpr	4	2	0.301	1.204
fokus	1	1	0.477	0.477
gelar	1	1	0.477	0.477

guna	1	1	0.477	0.477
hal	1	1	0.477	0.477
hari	1	1	0.477	0.477
heran	2	2	0.301	0.602
hukum	2	1	0.477	0.954
iii	2	2	0.301	0.602
indonesia	2	1	0.477	0.954
jaksa	1	1	0.477	0.477
kenapa	2	2	0.301	0.602
kepala	1	1	0.477	0.477
kerap	1	1	0.477	0.477
kerja	1	1	0.477	0.477
ketimbang	1	1	0.477	0.477
ketua	2	2	0.301	0.602
komisi	2	2	0.301	0.602
konstitusi	2	1	0.477	0.954
korupsi	3	1	0.477	1.431
kpk	8	2	0.301	2.408
kurang	1	1	0.477	0.477
laku	6	2	0.301	1.806
lama	2	2	0.301	0.602
laode	3	1	0.477	1.431
mahkamah	1	1	0.477	0.477
masalah	5	2	0.301	1.505
milik	1	1	0.477	0.477
operasi	1	1	0.477	0.477
padahal	3	2	0.301	0.903
paham	1	1	0.477	0.477
para	2	1	0.477	0.954
patut	1	1	0.477	0.477
pidana	1	1	0.477	0.477
pihak	1	1	0.477	0.477
polisi	1	1	0.477	0.477
proses	3	1	0.477	1.431
punya	1	1	0.477	0.477
putus	1	1	0.477	0.477
rahardjo	1	1	0.477	0.477
rapat	1	1	0.477	0.477
rasa	1	1	0.477	0.477
sadap	5	1	0.477	2.385
saya	1	1	0.477	0.477
semua	2	1	0.477	0.954

sikap	1	1	0.477	0.477
suai	1	1	0.477	0.477
tangan	1	1	0.477	0.477
tangkap	1	1	0.477	0.477
tegak	1	1	0.477	0.477
tentang	1	1	0.477	0.477
tindak	3	1	0.477	1.431
turut	3	2	0.301	0.903
ujar	1	1	0.477	0.477
undang	2	1	0.477	0.954
wakil	1	1	0.477	0.477
wenang	2	1	0.477	0.954

Dari proses penghitungan TF.IDF yang ditunjukkan Tabel 3.6 dapat diperoleh bobot kalimat berdasarkan *Global Sentence Weighting* (W_2) adalah seperti Tabel 3.7 dan Tabel 3.8 berikut.

Tabel 3.7 Bobot Global Sentence Weighting (W_2) untuk dokumen d_1

S_i	$TF.IDF$	W_2
1	$\log(1 + ((0.602 + 0.602 + 1.204 + 0.477 + 0.477 + 0.477 + 0.477 + 2.408 + 0.477) / 9))$	0.2553
2	$\log(1 + ((1.505 + 0.477 + 1.505 + 0.477 + 0.477 + 0.477 + 0.954 + 0.477 + 0.477) / 9))$	0.24513
3	$\log(1 + ((0.602 + 2.408 + 0.954 + 0.477 + 0.477 + 0.602 + 0.602 + 1.204 + 1.505 + 1.431 + 1.431 + 2.408 + 0.602 + 0.477 + 1.431 + 1.431 + 1.431) / 17))$	0.33152
4	$\log(1 + ((0.903 + 0.903 + 0.954 + 0.477 + 0.477 + 2.408 + 0.477 + 1.806 + 1.431 + 1.431 + 0.954 + 1.806 + 1.431) / 13))$	0.34026
5	$\log(1 + ((0.903 + 1.204 + 0.477 + 0.477 + 0.477 + 1.431 + 1.806 + 2.408 + 1.431 + 1.431 + 0.477 + 1.431) / 12))$	0.33501

Tabel 3.8 Bobot Global Sentence Weighting (W_2) untuk dokumen d_2

S_i	$TF.IDF$	W_2
-------	----------	-------

1	$\log(1 + ((0.477 + 0.602 + 2.408 + 1.431 + 0.477 + 0.602 + 0.477 + 1.204 + 0.477 + 0.602 + 0.602 + 0.477 + 1.505 + 2.385 + 1.806 + 0.477) / 16)$	0.30115
2	$\log(1 + ((0.903 + 0.477 + 0.954 + 0.954 + 0.477 + 0.477 + 0.477 + 0.477 + 0.954 + 1.806 + 2.385 + 0.477) / 12)$	0.2791
3	$\log(1 + ((0.477 + 0.477 + 0.602 + 2.385 + 2.408 + 1.505 + 0.903 + 0.477 + 0.954 + 0.954 + 0.477 + 0.954 + 2.385 + 0.477 + 1.431) / 15)$	0.32724
4	$\log(1 + ((0.903 + 1.431 + 0.602 + 2.408 + 1.806 + 2.385 + 0.477 + 0.954 + 0.954) / 9)$	0.36632
5	$\log(1 + ((0.477 + 0.477 + 0.954 + 0.477 + 0.954) / 5)$	0.22214

3.3.3.3. *Sentence position* (W_3)

Sentence position merupakan pembobotan kalimat berdasarkan posisi kalimat dalam suatu dokumen. Proses pembobotan ini (W_3) mengadopsi penelitian (Mei & Chen, 2012) dimana kalimat yang berada diawal dokumen memiliki skor yang tinggi dibanding kalimat dengan posisi terakhir. Pembobotan kalimat dengan pendekatan *sentence position* didasarkan atas penelitian (Verdianto et al., 2016) yang mengevaluasi hasil peringkasan, dimana posisi kalimat pada suatu dokumen berita yang berada pada awal cenderung memiliki bobot yang tinggi daripada kalimat yang berada pada akhir. Hal ini didasarkan atas pernyataan bahwa sebagian besar berita cenderung menyampaikan ide pokoknya pada awal-awal kalimat sedangkan kalimat- kalimat selanjutnya merupakan penjelas atau bahkan informasi-informasi lain di luar pokok bahasan.

Pembobotan kalimat berdasarkan posisi kalimat dapat dijelaskan pada persamaan 3.3

$$W_3(S_i) = \frac{1}{\sqrt{POS(S_i)}} \quad (3.3)$$

Dimana,

$POS(S_i)$: Posisi kalimat i (S_i) pada dokumen

Contoh pembobotan dengan *sentence position* yang mengacu pada dokumen d_1 adalah seperti Tabel 3.9 berikut.

Tabel 3.9 Contoh pembobotan *Sentence Position* pada dokumen d_1

Kalimat Ke	W_3
1	1
2	0.707
3	0.577
4	0.5
5	0.477

3.3.3.4. Informasi Gramatikal dengan *POS Tagging Distribution*

Setiap kalimat mengandung informasi gramatikal yang dapat mengindikasikan penting tidaknya kalimat tersebut pada suatu dokumen. Informasi gramatikal yang dikandung oleh kalimat dapat ditunjukkan dengan pendekatan *Part of Speech Tagging (POS Tagging)*.

POS Tagging Distribution merupakan pembobotan kalimat berdasarkan persebaran informasi gramatikal yang dikandung suatu kata. Kelas kata (label POS) yang ada pada informasi gramatikal memiliki peran penting dalam menentukan adanya kata informatif dalam suatu kalimat. Nilai label *POS* diperoleh berdasarkan penelitian (Lioma & Blanco, 2009) yang menjelaskan tentang Jespersen's Rank Theory, dimana label *POS* (p) yang memiliki nilai tinggi berdasarkan ranking secara berturut-turut adalah kata benda (*noun*), kata kerja (*verb*), kata sifat (*adverb*), label lainnya (*other*).

Kata yang memiliki persebaran tinggi dan memiliki nilai label *POS* yang tinggi akan memberikan bobot tinggi pula terhadap kalimat. Pembobotan ini mengadopsi pendekatan *term frequency* dengan menambahkan nilai label *POS* dalam pembobotannya. Berdasarkan Jespersen's Rank Theory, pemberian nilai bobot label *POS* (PW_p) yang diberikan terhadap *noun*, *verb*, *adverb* & *adjective*, dan *other* (label *POS* selain *noun*, *verb*, *adverb* & *adjective*) secara berturut-turut adalah 1, 0.75, 0.5, dan 0.25. Sehingga dapat dikelompokkan tag label dari *POS tagging* pada pembahasan Bab 2.2 kedalam empat label *POS* seperti Tabel 3.10.

Tabel 3.10 Kelompok label POS Tagging

POS Label	Tag	Bobot POS
<i>Noun</i>	NN, NNP, PRP, PR	1
<i>Verb</i>	VB	0.75
<i>Adverb</i>	RB, JJ	0.5
<i>Other</i>	WH, MD, CD, NEG, IN, CC, SC, WDT, FW	0.25

Term-term yang memiliki tag yang sesuai dengan kelompok label POS, akan diproses dan diberi bobot sesuai dengan nilai bobot masing-masing. Dalam proses perhitungan, *POS Tagging Distribution* dibagi menjadi dua yaitu

a. POS Tagging Local Distribution (W_4)

POS Tagging Local Distribution ditujukan untuk menghitung tingkat persebaran *term* yang berlabel *POS p* pada satu dokumen. Mengadopsi dari penelitian (Arifin, Abdullah, & Rosyadi, 2018) yang menyebutkan bahwa sebuah *term* yang tersebar luas pada suatu dokumen memiliki nilai yang tinggi dibandingkan *term* lain, karena sebuah *term* yang tersebar dalam dokumen lebih mempresentasikan topik dari dokumen tersebut. Dari pernyataan tersebut dapat diformulasikan mengenai persebaran *term* dengan pendekatan *POS Tagging*.

Proses perhitungan *POS Tagging Local Distribution* dapat dilihat seperti persamaan 3.4

$$W_4(S_{d,i}) = \log \left(1 + \frac{\sum_{j=1}^k (TF_{d,p,j} * PW_p)}{k} \right). \quad (3.4)$$

Dimana,

$TF_{d,p,j}$: *Term frequency* untuk *term j* yang berlabel *POS p* pada dokumen *d*

PW_p : Nilai bobot untuk label *POS p*

k : jumlah total *term* pada kalimat *i*

Dari contoh kalimat pada Tabel 3.2. di atas akan diproses menggunakan *POS Tagging* untuk Bahasa Indonesia. Hasil dari proses *POS Tagging* Bahasa Indonesia merupakan kalimat yang kata-kata didalamnya diimbui akhiran nilai *tag* dari proses *POS Tagging*. Untuk lebih jelasnya dapat dilihat seperti Tabel 3.11.

Tabel 3.11 Kalimat hasil POS Tagging untuk Bahasa Indonesia

No	Kalimat
1	Komisi/NN III/NNP DPR/NNP menggelar/VB Rapat/NNP Dengar/VB Pendapat/VB dengan/SC KPK/NNP hari/NN ini/PR .
2	Masalah/NN yang/SC paling/RB dibahas/VB adalah/VB masalah/NN Operasi/NNP Tangkap/NNP Tangan/NNP para/WDT kepala/NN daerah/NN.
3	Ketua/NN KPK/NNP, Agus/NNP Rahardjo/NNP merasa/VB heran/VB kenapa/SC DPR/NNP malah/CC mempermasalahkan/VB proses/NN penindakan/NN KPK/NNP selama/JJ ini/PR, ketimbang/SC proses/NN pencegahan/NN korupsi/NN.
4	Padahal/CC menurut/VB Agus/NNP, sebagian/NN besar/NN anggaran/NN KPK/NNP digunakan/VB untuk/SC melakukan/VB pencegahan/NN dan/CC menindak/VB para/WDT pelaku/NN korupsi/NN.
5	Menurutnya/NNP, DPR/NNP sudah/MD sepatutnya/JJ fokus/NN mengawasi/VB proses/NN yang/SC dilakukan/VB KPK/NNP dalam/IN mencegah/VB tindak/NN pidana/NN korupsi/NN.

Dari contoh kalimat di atas *term* yang telah melalui tahap *text preprocessing* akan memiliki nilai yang berbeda-beda. Untuk lebih jelasnya bisa mengacu pada Tabel 3.12.

Tabel 3.12 Frekuensi *term* setelah *POS Tagging*

<i>Term</i>	<i>TF</i>	<i>TF_{d,Noun}</i>	<i>TF_{d,Verb}</i>	<i>TF_{d,Adverb}</i>	<i>TF_{d,Other}</i>
agus	2	2	0	0	0
anggar	1	1	0	0	0
awas	1	0	1	0	0
bagi	1	1	0	0	0
bahas	1	0	1	0	0
cegah	3	2	1	0	0
daerah	1	1	0	0	0
dapat	1	0	1	0	0
dengar	1	0	1	0	0
dpr	3	3	0	0	0

fokus	1	1	0	0	0
gelar	1	0	1	0	0
guna	1	0	1	0	0
hari	1	1	0	0	0
heran	1	0	1	0	0
iii	1	1	0	0	0
kenapa	1	0	1	0	1
kepala	1	1	0	0	0
ketimbang	1	0	0	0	1
ketua	1	1	0	0	0
komisi	1	1	0	0	0
korupsi	3	3	0	0	0
kpk	5	5	0	0	0
laku	3	1	2	0	0
lama	1	0	0	1	0
masalah	3	2	1	0	0
operasi	1	1	0	0	0
padahal	1	0	0	0	1
para	2	0	0	0	2
patut	1	0	0	1	0
pidana	1	1	0	0	0
proses	3	3	0	0	0
raharjo	1	1	0	0	0
rapat	1	1	0	0	0
rasa	1	0	1	0	0
tangan	1	1	0	0	0
tangkap	1	1	0	0	0
tindak	3	2	1	0	0
turut	2	1	1	0	0

Jika kita perhatikan Tabel 3.12 terdapat *term* yang memiliki frekuensi kemunculan di lebih dari satu label *POS* (*term* yang diberi blok warna hijau). *Term-term* tersebut memiliki label yang berbeda-beda akan tetapi memiliki kata dasar yang sama. Seperti contoh kata dasar “laku” yang terdapat pada kata “pelaku” dengan label *noun*, “melakukan” dengan label *verb*, dan “dilakukan” dengan label *verb*. Hal inilah yang menjadi dasar penggunaan *POS Tagging* untuk menentukan bobot *term* sesuai dengan labelnya. Untuk pembobotan kalimat pada *POS Tagging Local Distribution* bisa mengacu pada Tabel 3.13.

Tabel 3.13 Pembobotan Kalimat berdasarkan *POS Tagging Local Distribution*

No	Kalimat	W_4
1	Komisi/NN (1 * 1) + III/NNP (1 * 1) + DPR/NNP (3 * 1) + menggelar/VB (1 * 0.75) + Rapat/NNP (1 * 1) + Dengar/VB (1 * 0.75) + Pendapat/VB (1 * 0.75) + dengan/SC (0 * 0.25) + KPK/NNP (5 * 1) + hari/NN (1 * 1) + ini/PR (0 * 1)	0.41218
2	Masalah/NN (2 * 1) + yang/SC (0 * 0.25) + paling/RB (0 * 0.5) + dibahas/VB (1 * 0.75) + adalah/VB (0 * 0.75) + masalah/NN (2 * 1) + Operasi/NNP (1 * 1) + Tangkap/NNP (1 * 1) + Tangan/NNP (1 * 1) + para/WDT (2 * 0.25) + kepala/NN (1 * 1) + daerah/NN (1 * 1)	0.33019
3	Ketua/NN (1 * 1) + KPK/NNP (5 * 1) + Agus/NNP (2 * 1) + Rahardjo/NNP (1 * 1) + merasa/VB (1 * 0.75) + heran/VB (1 * 0.75) + kenapa/SC (1 * 0.75) + DPR/NNP (3 * 1) + malah/CC (0 * 0.25) + mepermasalahkan/VB (1 * 0.75) + proses/NN (3 * 1) + penindakan/NN (2 * 1) + KPK/NNP (5 * 1) + selama/JJ (1 * 0.5) + ini/PR (0 * 1) + ketimbang/SC (1 * 0.25) + proses/NN (3 * 1) + pencegahan/NN (2 * 1) + korupsi/NN (3 * 1)	0.45753
4	Padahal/CC (1 * 0.25) + menurut/VB (1 * 0.75) + Agus/NNP (2 * 1) + sebagian/NN (1 * 1) + besar/NN (0 * 1) + anggaran/NN (1 * 1) + KPK/NNP (5 * 1) + digunakan/VB (1 * 0.75) + untuk/SC (0 * 0.25) + melakukan/VB (2 * 0.75) + pencegahan/NN (2 * 1) + dan/CC (0 * 0.25) + menindak/VB (1 * 0.75) + para/WDT (2 * 0.25) + pelaku/NN (1 * 1) + korupsi/NN (3 * 1)	0.38437
5	Menurutnya/NNP (1 * 1) + DPR/NNP (3 * 1) + sudah/MD (0 * 0.25) + sepatutnya/JJ (1 * 0.5) + fokus/NN (1 * 1) + mengawasi/VB (1 * 0.75) + proses/NN (3 * 1) + yang/SC (0 * 0.25) + dilakukan/VB (2 * 0.75) + KPK/NNP (5 * 1) + dalam/IN (0 * 0.25) + mencegah/VB (1 * 0.75) + tindak/NN (2 * 1) + pidana/NN (1 * 1) + korupsi/NN (3 * 1)	0.45864

Tabel 3.13 menunjukkan bahwa satu *term* dapat memiliki lebih dari 1 label POS, dan dalam perhitungan *POS Tagging Local Distribution* pemberian bobot untuk tiap *term* tergantung pada label POS yang dikandung. Seperti contoh *term* “laku” pada kalimat ke-4. Pada kalimat ke-4 *term* “laku” memiliki label *noun* dan memiliki frekuensi kemunculan untuk label yang sama adalah 1, sehingga bobot untuk *term* “laku” dengan label *noun* adalah $(1 * 1) = 1$. Selain itu kalimat ke-4 juga memiliki *term* “laku” yang berlabel *verb* dan frekuensi kemunculan *term* “laku” untuk label *verb* ada 2 (pada kalimat ke-4 dan ke-5), sehingga bobot untuk *term* “laku” dengan label *verb* adalah $(2 * 0.75) = 1.5$.

b. POS Tagging Global Distribution (W_5)

Sama halnya dengan *POS Tagging Local Distribution* yang menghitung persebaran *term* pada satu dokumen, *POS Tagging Global Distribution* digunakan untuk mengetahui tingkat persebaran *term* yang berlabel POS sama pada seluruh dokumen. Proses perhitungan *POS Tagging Local Distribution* dapat dilihat seperti persamaan 3.5

$$W_5(S_i) = \log \left(1 + \frac{\sum_{j=1}^k (TF_{p,j} * PW_p)}{k} \right). \tag{3.5}$$

Dimana,

$TF_{p,j}$: *Term frequency* untuk *term j* yang berlabel POS p

PW_p : Nilai bobot untuk label POS p

k : jumlah total *term* pada kalimat i

Contoh kasus pada *POS Tagging Global Distribution* dapat mengacu pada contoh kasus *POS Tagging Local Distribution* yang telah dijabarkan sebelumnya, seperti pada Table 3.14.

Tabel 3.14 Kalimat hasil POS Tagging untuk Bahasa Indonesia

Dokumen	Kalimat
d_1	Komisi/NN III/NNP DPR/NNP menggelar/VB Rapat/NNP Dengar/VB Pendapat/VB dengan/SC KPK/NNP hari/NN ini/PR .

	<p>Masalah/NN yang/SC paling/RB dibahas/VB adalah/VB masalah/NN Operasi/NNP Tangkap/NNP Tangan/NNP para/WDT kepala/NN daerah/NN.</p> <p>Ketua/NN KPK/NNP, Agus/NNP Rahardjo/NNP merasa/VB heran/VB kenapa/SC DPR/NNP malah/CC mepermasalahkan/VB proses/NN penindakan/NN KPK/NNP selama/JJ ini/PR, ketimbang/SC proses/NN pencegahan/NN korupsi/NN.</p> <p>Padahal/CC menurut/VB Agus/NNP, sebagian/NN besar/NN anggaran/NN KPK/NNP digunakan/VB untuk/SC melakukan/VB pencegahan/NN dan/CC menindak/VB para/WDT pelaku/NN korupsi/NN.</p> <p>Menurutnya/NNP, DPR/NNP sudah/MD sepatutnya/JJ fokus/NN mengawasi/VB proses/NN yang/SC dilakukan/VB KPK/NNP dalam/IN mencegah/VB tindak/NN pidana/NN korupsi/NN.</p>
<i>d₂</i>	<p>Wakil/NN Ketua/NNP KPK/NNP, Laode/NNP mengaku/VB heran/VB dengan/SC sikap/NN DPR/NNP dalam/IN hal/NN ini/PR adalah/VB Komisi/NNP III/NNP, kerap/RB mempermasalahkan/VB penyadapan/NN yang/SC dilakukan/VB oleh/IN pihaknya/NN.</p> <p>Padahal/CC semua/CD aparat/NN hukum/VB di/IN Indonesia/NNP, baik/JJ itu/PR Kepolisian/NNP, dan/CC Jaksa/NNP memiliki/VB kewenangan/NN untuk/SC melakukan/VB penyadapan/NN dalam/IN bekerja/VB.</p> <p>"Saya/PRP kurang/RB paham/NN, kenapa/WH penyadapan/NN di/IN KPK/NNP selalu/RB dipermasalahkan/VB, padahal/CC semua/Cd penegak/NN hokum/NN di/IN Indonesia/NNP mempunyai/VB kewenangan/NN itu/PR (penyadapan)/NN," ujar/VB Laode/NNP.</p> <p>Menurut/NNP Laode/NNP, selama/JJ ini/PR KPK/NNP melakukan/VB penyadapan/NN sudah/MD sesuai/JJ dengan/SC undang/NN undang/NN yang/SC ada/JJ.</p>

Bahkan/RB sudah/MD diputuskan/VB oleh/IN Mahkamah/NNP konstitusi/NN, bahwa/SC tidak/NEG bertentangan/VB dengan/SC konstitusi/NN.

Dari contoh kalimat di atas *term* yang telah melalui tahap *text preprocessing* akan memiliki nilai yang berbeda-beda. Untuk lebih jelasnya bisa mengacu pada Tabel 3.15.

Tabel 3.15 Contoh penghitungan TF.IDF untuk setiap *term* pada dokumen d_1 dan d_2

<i>Term</i>	<i>TF</i>	<i>TF_{d,Noun}</i>	<i>TF_{d,Verb}</i>	<i>TF_{d,Adverb}</i>	<i>TF_{d,Other}</i>
agus	2	2	0	0	0
aku	1	0	1	0	0
anggar	1	1	0	0	0
apparat	1	1	0	0	0
awas	1	0	1	0	0
bagi	1	1	0	0	0
bahas	1	0	1	0	0
baik	1	0	0	1	0
cegah	3	2	1	0	0
daerah	1	1	0	0	0
dapat	1	0	1	0	0
dengar	1	0	1	0	0
dpr	4	4	0	0	0
fokus	1	1	0	0	0
gelar	1	0	1	0	0
guna	1	0	1	0	0
hal	1	1	0	0	0
hari	1	1	0	0	0
heran	2	0	2	0	0
hukum	2	1	1	0	0
iii	2	2	0	0	0
indonesia	2	2	0	0	0
jaksa	1	1	0	0	0
kenapa	2	0	0	0	2
kepala	1	1	0	0	0
kerap	1	0	0	1	0
kerja	1	0	1	0	0
ketimbang	1	0	0	0	1

ketua	2	2	0	0	0
komisi	2	2	0	0	0
konstitusi	2	2	0	0	0
korupsi	3	3	0	0	0
kpk	8	8	0	0	0
kurang	1	0	0	1	0
laku	6	1	5	0	0
lama	2	0	0	2	0
laode	3	3	0	0	0
mahkamah	1	1	0	0	0
malah	1	0	0	0	1
masalah	5	2	3	0	0
milik	1	0	1	0	0
operasi	1	1	0	0	0
padahal	3	0	0	0	3
paham	1	1	0	0	0
para	2	0	0	0	2
patut	1	0	0	1	0
pidana	1	1	0	0	0
pihak	1	1	0	0	0
polisi	1	1	0	0	0
proses	3	3	0	0	0
punya	1	0	1	0	0
putus	1	0	1	0	0
rahardjo	1	1	0	0	0
rapat	1	1	0	0	0
rasa	1	0	1	0	0
sadap	5	5	0	0	0
saya	1	1	0	0	0
semua	2	0	0	0	2
sikap	1	1	0	0	0
suai	1	0	0	1	0
tangan	1	1	0	0	0
tangkap	1	1	0	0	0
tegak	1	1	0	0	0
tentang	1	0	1	0	0
tindak	3	2	1	0	0
turut	3	2	1	0	0
ujar	1	0	1	0	0
undang	2	2	0	0	0

wakil	1	1	0	0	0
wenang	2	2	0	0	0

Jika kita perhatikan Tabel 3.15 terdapat *term* yang memiliki frekuensi kemunculan di lebih dari satu label *POS* (*term* yang diberi blok warna hijau). *Term-term* tersebut memiliki label yang berbeda-beda akan tetapi memiliki kata dasar yang sama. Hal inilah yang menjadi dasar penggunaan *POS Tagging* untuk menentukan bobot *term* sesuai dengan labelnya. Untuk pembobotan kalimat pada *POS Tagging Global Distribution* bisa mengacu pada Tabel 3.16.

Tabel 3.16 Kalimat hasil POS Tagging untuk Bahasa Indonesia

Doc	Kalimat	W_5
	Komisi/NN (2 * 1) + III/NNP (2 * 1) + DPR/NNP (4 * 1) + menggelar/VB (1 * 0.75) + Rapat/NNP (1 * 1) + Dengar/VB (1 * 0.75) + Pendapat/VB (1 * 0.75) + dengan/SC (0 * 0.25) + KPK/NNP (8 * 1) + hari/NN (1 * 1) + ini/PR (0 * 1).	0.51188
	Masalah/NN (2 * 1) + yang/SC (0 * 0.25) + paling/RB (0 * 0.5) + dibahas/VB (1 * 0.75) + adalah/VB (0 * 0.75) + masalah/NN (2 * 1) + Operasi/NNP (1 * 1) + Tangkap/NNP (1 * 1) + Tangan/NNP (1 * 1) + para/WDT (2 * 0.25) + kepala/NN (1 * 1) + daerah/NN (1 * 1).	0.33019
d_1	Ketua/NN (2 * 1) + KPK/NNP (8 * 1) + Agus/NNP (2 * 1) + Rahardjo/NNP (1 * 1) + merasa/VB (1 * 0.75) + heran/VB (2 * 0.75) + kenapa/SC (2 * 0.25) + DPR/NNP (4 * 1) + malah/CC (0 * 0.25) + mempermasalahkan/VB (3 * 0.75) + proses/NN (3 * 1) + penindakan/NN (2 * 1) + KPK/NNP (8 * 1) + selama/JJ (2 * 0.5) + ini/PR (0 * 1) +, ketimbang/SC (1 * 0.25) + proses/NN (3 * 1) + pencegahan/NN (2 * 1) + korupsi/NN (8 * 1).	0.59074
	Padahal/CC (3 * 0.25) + menurut/VB (1 * 0.75) + Agus/NNP (2 * 1) +, sebagian/NN (1 * 1) + besar/NN (0 * 1) + anggaran/NN (1 * 1) + KPK/NNP (8 * 1) + digunakan/VB (1 * 0.75) + untuk/SC (0 * 0.25) + melakukan/VB (5 * 0.75) + pencegahan/NN (2 * 1) + dan/CC (0 * 0.25) + menindak/VB (1	0.46869

	<p>* 0.75) + para/WDT (2 * 0.25) + pelaku/NN (1 * 1) + korupsi/NN (3 * 1).</p>	
	<p>Menurutnya/NNP(2 * 1) +, DPR/NNP (4 * 1) + sudah/MD (0 * 0.25) + sepatutnya/JJ (1 * 0.5) + fokus/NN (1 * 1) + mengawasi/VB (1 * 0.75) + proses/NN (3 * 1) + yang/SC (0 * 0.25) + dilakukan/VB (5 * 0.75) + KPK/NNP (8 * 1) + dalam/IN (0 * 0.25) + mencegah/VB (1 * 0.75) + tindak/NN (2 * 1) + pidana/NN (1 * 1) + korupsi/NN (3 * 1).</p>	0.54148
	<p>Wakil/NN (1 * 1) + Ketua/NNP (2 * 1) + KPK/NNP(8 * 1) +, Laode/NNP (3 * 1) + mengaku/VB (1 * 0.75) + heran/VB (2 * 0.75) + dengan/SC (0 * 0.25) + sikap/NN (1 * 1) + DPR/NNP (4 * 1) + dalam/IN (0 * 0.25) + hal/NN (1 * 1) + ini/PR (0 * 1) + adalah/VB (0 * 0.75) + Komisi/NNP (2 * 1) + III/NNP(2 * 1) +, kerap/RB (1 * 0.5) + mempermasalahkan/VB (3 * 0.75) + penyadapan/NN (5 * 1) + yang/SC (0 * 0.25) + dilakukan/VB (5 * 0.75) + oleh/IN (0 * 0.25) + pihaknya/NN (1 * 1) .</p>	0.53426
d_2	<p>Padahal/CC (3 * 0.25) + semua/CD (0 * 0.25) + aparat/NN (1 * 1) + hukum/VB (1 * 0.75) + di/IN (0 * 0.25) + Indonesia/NNP (2 * 1) +, baik/JJ (1 * 0.5) + itu/PR (0 * 1) + Kepolisian/NNP(1 * 1) +, dan/CC (0 * 0.25) + Jaksa/NNP (1 * 1) + memiliki/VB (1 * 0.75) + kewenangan/NN (2 * 1) + untuk/SC (0 * 0.25) + melakukan/VB (5 * 0.75) + penyadapan/NN (5 * 1) + dalam/IN (0 * 0.25) + bekerja/VB (1 * 0.75).</p>	0.41567
	<p>"Saya/PRP (1 * 1) + kurang/RB (0 * 0.5) + paham/NN (1 * 1) +, kenapa/WH (2 * 0.25) + penyadapan/NN (5 * 1) + di/IN (0 * 0.25) + KPK/NNP (8 * 1) + selalu/RB (0 * 0.5) + dipermasalahkan/VB (3 * 0.75) +, padahal/CC (3 * 0.25) + semua/CD (0 * 0.25) + penegak/NN (1 * 1) + hukum/NN (1 * 1) + di/IN (0 * 0.25) + Indonesia/NNP (2 * 1) + mempunyai/VB (1 * 0.75) + kewenangan/NN (2 * 1) + itu/PR (0 * 1) + (penyadapan)/NN (5 * 1) +," ujar/VB (1 * 0.75) + Laode/NNP (3 * 1).</p>	0.5141

Menurut/NNP (2 * 1) + Laode/NNP (3 * 1) +, selama/JJ (2 * 0.5) 0.60507
 + ini/PR (0 * 1) + KPK/NNP (8 * 1) + melakukan/VB (5 * 0.75)
 + penyadapan/NN (5 * 1) + sudah/MD (0 * 0.25) + sesuai/JJ (1
 * 0.5) + dengan/SC (0 * 0.25) + undang/NN (2 * 1) + undang/NN
 (2 * 1) + yang/SC (0 * 0.25) + ada/JJ (0 * 0.5).

Bahkan/RB (0 * 0.5) + sudah/MD (0 * 0.25) + diputuskan/VB (1 0.36173
 * 0.75) + oleh/IN (0 * 0.25) + Mahkamah/NNP (1 * 1) +
 konstitusi/NN (2 * 1) +, bahwa/SC (0 * 0.25) + tidak/NEG (0 *
 0.25) + bertentangan/VB (1 * 0.75) + dengan/SC (0 * 0.25) +
 konstitusi/NN (2 * 1).

3.3.3.5. Relevansi kalimat terhadap judul

Pembobotan kalimat berdasarkan relevansi kalimat terhadap judul merupakan pembobotan kalimat yang ditujukan untuk mengetahui tingkat kemiripan kalimat dengan judul dengan menggunakan dua aspek yaitu kemiripan rangkaian kata yang menyusun kalimat dengan pendekatan *n-gram word similarity*, dan kemiripan konteks makna kata penyusun kalimat dengan pendekatan *query expansion similarity*.

a. *N-gram Word Similarity (W₆)*

Pembobotan ini berdasarkan kemiripan *n* rangkaian kata antara dua kalimat, yaitu kalimat berita dengan judul berita. Dalam pembobotan ini, semakin banyak *n* rangkaian kata yang mirip antara kalimat dengan judul, maka semakin tinggi bobot kalimat tersebut. Hal ini mengindikasikan bahwa kalimat tersebut memiliki tingkat kemiripan yang tinggi dengan judul.

Perhitungan bobot ini mengacu pada persamaan 2.11 untuk memberikan bobot kemiripan kalimat *S_i* terhadap judul (*title*)

$$W_6(S_i) = \log \left(1 + \frac{\sum_{w=1}^n \left(\frac{NTW_w}{TW} \right)}{n} \right), \quad n = \min(\text{length}(S_i), \text{length}(\text{title})) \quad (3.6)$$

Dimana,

- NTW_w : jumlah rangkaian kata pada kalimat S_i yang mirip dengan rangkaian kata pada judul pada w level rangkaian
- T_w : Jumlah rangkaian kata pada judul pada w level rangkaian
- n : nilai minimum dari panjang kalimat antara judul dengan kalimat S_i .

Contoh mengacu pada dokumen d_1 dengan judul “Ketua KPK Heran DPR Mempermasalahkan Penindakan KPK” dengan panjang kalimat 7 kata, dan mengambil contoh kalimat ketiga (S_3) “Ketua KPK, Agus Rahardjo merasa heran kenapa DPR malah mepermasalahkan proses penindakan KPK selama ini, ketimbang proses pencegahan korupsi.” dengan panjang kalimat 19 kata. Sehingga nilai n yang didapat adalah 7. Proses pembentukan n-gram dengan $n = 7$ pada kalimat judul dan kalimat S_i dapat dilihat pada Tabel 3.17.

Tabel 3.17 Proses pembentukan n-gram dengan $n = 7$ pada dokumen d_1

n	Judul	Kalimat S_i	$\frac{NTW_w}{T_w}$
1	“ketua”, “kpk”, “heran”, “dpr”, “masalah”, “tindak”, “kpk”	“ketua”, “kpk”, “agus”, “rahardjo”, “rasa”, “heran”, “kenapa”, “dpr”, “malah”, “masalah”, “proses”, “tindak”, “kpk”, “lama”, “ini”, “ketimbang”, “cegah”, “korupsi”	1.28571
2	“ketua kpk”, “kpk heran”, “heran dpr”, “dpr masalah”, “masalah tindak”, “tindak kpk”	“ketua kpk”, “kpk agus”, “agus rahardjo”, “rahardjo rasa”, “rasa heran”, “heran kenapa”, “kenapa dpr”, “dpr malah”, “malah masalah”, “masalah proses”, “proses tindak”, “tindak kpk”, “kpk lama”, “lama ini”, “ini ketimbang”, “ketimbang proses”, “proses cegah”, “cegah korupsi”	0.33333
3	“ketua kpk heran”, “kpk heran dpr”, “heran dpr	“ketua kpk agus”, “kpk agus rahardjo”, “agus rahardjo rasa”, “rahardjo rasa heran”, “rasa heran kenapa”, “heran kenapa dpr”, “kenapa dpr malah”, “dpr malah masalah”, “malah	0

	masalah”, “dpr masalah tindak”, “masalah tindak kpk”	masalah proses”, “masalah proses tindak”, “proses tindak kpk”, “tindak kpk lama”, “kpk lama ini”, “lama ini ketimbang”, “ini ketimbang cegah”, “ketimbang cegah korupsi”	
4	“ketua kpk heran dpr”, “kpk heran dpr masalah”, “heran dpr masalah tindak”, “dpr masalah tindak kpk”	“ketua kpk agus rahardjo”, “kpk agus rahardjo rasa”, “agus rahardjo rasa heran”, “rahardjo rasa heran kenapa”, “rasa heran kenapa dpr”, “heran kenapa dpr malah”, “kenapa dpr malah masalah”, “dpr malah masalah proses”, “malah masalah proses tindak”, “masalah proses tindak kpk”, “proses tindak kpk lama”, “tindak kpk lama ini”, “kpk lama ini ketimbang”, “lama ini ketimbang cegah”, “ini ketimbang cegah korupsi”	0
5	“Ketua kpk heran dpr masalah”, “kpk heran dpr masalah tindak”, “heran dpr masalah tindak kpk”	“ketua kpk agus rahardjo rasa”, “kpk agus rahardjo rasa heran”, “agus rahardjo rasa heran kenapa”, “rahardjo rasa heran kenapa dpr”, “rasa heran kenapa dpr malah”, “heran kenapa dpr malah masalah”, “kenapa dpr malah masalah proses”, “dpr malah masalah proses tindak”, “malah masalah proses tindak kpk”, “masalah proses tindak kpk lama”, “proses tindak kpk lama ini”, “tindak kpk lama ini ketimbang”, “kpk lama ini ketimbang cegah”, “lama ini ketimbang cegah korupsi”	0
6	“Ketua kpk heran dpr masalah tindak”, “kpk heran dpr masalah tindak kpk”	“ketua kpk agus rahardjo rasa heran”, “kpk agus rahardjo rasa heran kenapa”, “agus rahardjo rasa heran kenapa dpr”, “rahardjo rasa heran kenapa dpr malah”, “rasa heran kenapa dpr malah masalah”, “heran kenapa dpr malah masalah proses”, “kenapa dpr malah masalah proses tindak”, “dpr malah masalah proses	0

	tindak kpk”, “malah masalah proses tindak kpk lama”, “masalah proses tindak kpk lama ini”, “proses tindak kpk lama ini ketimbang”, “tindak kpk lama ini ketimbang cegah”, “kpk lama ini ketimbang cegah korupsi”	
7 “Ketua kpk heran dpr masalah tindak kpk”	“ketua kpk agus rahardjo rasa heran kenapa”, “kpk agus rahardjo rasa heran kenapa dpr”, “agus rahardjo rasa heran kenapa dpr malah”, “rahardjo rasa heran kenapa dpr malah masalah”, “rasa heran kenapa dpr malah masalah proses”, “heran kenapa dpr malah masalah proses tindak”, “kenapa dpr malah masalah proses tindak kpk”, “dpr malah masalah proses tindak kpk lama”, “malah masalah proses tindak kpk lama ini”, “masalah proses tindak kpk lama ini ketimbang”, “proses tindak kpk lama ini ketimbang cegah”, “tindak kpk lama ini ketimbang cegah korupsi”	0

Dari proses perbandingan pada Tabel 3.17 dapat diketahui n-gram word similarity antara kalimat S_3 terhadap judul adalah

$$W_6(S_i) = \log\left(1 + \frac{(1.28571 + 0.33333 + 0 + 0 + 0 + 0 + 0)}{7}\right)$$

$$= \log(1 + 0.23129) = 0.0903$$

b. Query Expansion Similarity (W_7)

Pembobotan ini berdasarkan kemiripan makna kata antara dua kalimat. Dalam pembobotan ini, judul dianggap sebagai *query* dan dilakukan ekspansi/perluasan dengan menggunakan thesaurus. Perluasan kata pada judul dilakukan untuk mendapatkan kata alternatif yang memiliki kesamaan makna yang dimiliki oleh kalimat. Sehingga kalimat tersebut secara tidak langsung memiliki kesamaan dalam konteks makna kata. Untuk menghitung tingkat similaritas kalimat

terhadap judul berdasarkan kemiripan makna kata dapat dilakukan menggunakan persamaan 3.7

$$W_7(S_i) = \log \left(1 + \frac{\sum_{j=1}^k \left(\frac{NTW_{QE,j}}{T_{QE,j}} \right)}{n} \right) \quad (3.7)$$

Dimana,

- $NTW_{QE,j}$: jumlah *term* pada kalimat S_i yang mirip dengan *term* hasil perluasan kueri (*query expansion*) dari *term j* pada judul
- $T_{QE,j}$: Jumlah *term* hasil perluasan *term j* pada judul
- k : jumlah total *term* pada kalimat S_i
- n : jumlah kata yang ada pada judul

Contoh mengacu pada dokumen d_1 dengan judul “Ketua KPK Heran DPR Mempermasalahkan Penindakan KPK” dan terdapat suatu kalimat S_i “Agus Rahardjo merasa langkah DPR dalam mepermasalahkan tindakan KPK selama ini adalah salah dan terkesan aneh.”. Dalam perhitungan kemiripan kalimat berdasarkan *query expansion*, pertama judul akan dilakukan perluasan kueri (*query expansion*) pada setiap *term* yang ada menggunakan *library* kateglo yang dijelaskan pada pembahasan 2.8.1. Hasil dari *query expansion* dapat dilihat seperti Tabel 3.18.

Tabel 3.18 Hasil *query expansion* untuk judul dokumen

No	Term judul	Term hasil QE	Similar
1	ketua	pelopor, perintis, imam, kepala, komandan, pimpin	0
2	kpk	-	0
3	heran	kagum, takjub, pukau, pesona, kaget, kejut, peranjat, aneh	0.125
4	dpr	-	0
5	masalah	kasus, sulit, perkara	0
6	tindak	langkah, buat, aksi	0.33333
7	kpk	-	0

Dari proses perbandingan pada Tabel 3.18 dapat diketahui terdapat kesamaan antara kalimat S_i dengan hasil query expansion yaitu *term* “aneh” dan “langkah”. Sehingga proses penghitungan *query expansion similarity* antara kalimat S_i terhadap judul yang didapat adalah

$$\begin{aligned} W_7(S_i) &= \log\left(1 + \frac{(0 + 0 + 0.125 + 0 + 0 + 0.33333 + 0)}{7}\right) \\ &= \log(1 + 0.06547) = 0.02754 \end{aligned}$$

Setelah ketujuh pembobotan dilakukan, tahapan selanjutnya adalah akumulasi bobot pada tiap kalimat. Pembobotan W_1 dan W_4 sama-sama menghitung pada lingkup *local* (satu dokumen) maka dalam akumulasi ini dilakukan proses perkalian ($W_1 * W_4$). Begitu pula dengan W_2 dan W_5 yang melakukan perhitungan pada lingkup *global (corpus)*, sehingga dalam perhitungan ini dilakukan proses perkalian ($W_2 * W_5$). Proses ini terinspirasi atas penelitian (Wahib et al., 2015), dimana proses perkalian antara W_1 dengan W_4 dan W_2 dengan W_5 dilakukan agar bobot yang dimiliki pada masing-masing lingkup (*local* dan *global*) dapat saling menguatkan. Jika pada lingkup *local* W_1 atau *global* W_2 sebuah kalimat memiliki bobot yang besar, namun dalam lingkup *local* W_4 atau *global* W_5 ternyata kalimat tersebut memiliki bobot yang kecil maka dengan perkalian ini akan menurunkan nilai kalimat tersebut, begitu juga sebaliknya. Skor akhir dalam pembobotan kalimat didapat dengan cara menjumlahkan bobot yang telah dilakukan menggunakan persamaan 3.8.

$$Score(S_i) = (W_1 * W_4) + (W_2 * W_5) + W_3 + W_6 + W_7 \quad (3.8)$$

3.3.3.6. Penyusunan Ringkasan

Proses penyusunan ringkasan dilakukan berdasarkan ketujuh pembobotan kalimat ($W_1 - W_7$) yang menghasilkan skor kalimat ($Score(S_i)$). Proses pengambilan kalimat *representative* dilakukan dengan cara mengurutkan secara *descending* terhadap skor kalimat yang kemudian diambil *top-n* kalimat. Terdapat dua cara/teknik yang dapat dilakukan dalam penentuan pengambilan kalimat *representative*, yaitu

a. *Local-representative*

Merupakan teknik pengambilan kalimat *representative* secara *local* dimana cara penentuan kalimat *representative* dilakukan dengan mengambil 1 kalimat yang memiliki skor tertinggi di tiap dokumen pada satu topik dan mengurutkan kalimat-kalimat tersebut secara *descending* yang kemudian diambil *top-n* kalimat untuk dijadikan ringkasan. Apabila jumlah dokumen pada satu topik kurang dari *top-n* kalimat untuk dijadikan ringkasan, maka akan dilakukan teknik yang sama dengan mengambil 1 kalimat yang memiliki skor tertinggi ke-2 (dan seterusnya) pada tiap dokumen.

b. *Global-representative*

Merupakan teknik pengambilan kalimat *representative* secara *global* dimana cara penentuan kalimat *representative* dengan mengurutkan secara *descending* terhadap skor pada seluruh kalimat yang ada pada satu topik dan mengambil *top-n* kalimat untuk dijadikan ringkasan.

3.4. Pembuatan Perangkat Lunak

Pembuatan perangkat lunak bertujuan untuk mengimplementasikan model sistem yang di usulkan, mengatur proses pengelolaan data input dan menampilkan hasil output pada *user interface* yang dibangun. Perangkat lunak dikembangkan menggunakan multi bahasa pemrograman yaitu PHP, Python, SQL, dan Java. Sedangkan database penyimpanan menggunakan Mysql *database*.

3.5. Uji Coba Sistem

Pada tahapan ini dilakukan proses *training* sistem dan *testing* sistem. *Training* sistem dimaksudkan untuk mengestimasi nilai parameter yang optimal sehingga pada saat *testing* memperoleh hasil output yang maksimal. Parameter-parameter yang diestimasi tersebut adalah:

- Bobot label *POS Tagging*
- Penentuan pemilihan kalimat *representative* berdasarkan *local-representative* atau *global-representative*.

3.6. Metode Evaluasi Hasil Ringkasan

Untuk mengukur hasil ringkasan metode yang digunakan dalam penelitian ini adalah ROUGE. ROUGE (*Recall-Oriented Understudy for Gisting Evaluation*) adalah metode yang digunakan untuk mengukur kualitas dari sebuah ringkasan berdasarkan penelitian (Lin, 2004). ROUGE akan membandingkan antara rangkuman yang dihasilkan oleh sistem terhadap rangkuman ideal (*Groundtruth*) yang dibuat oleh pakar. ROUGE mengukur kualitas hasil ringkasan dengan menghitung unit-unit yang overlap seperti N-gram, urutan kata dan pasangan-pasangan kata antara ringkasan kandidat dan ringkasan sebagai referensi ROUGE sangat efektif digunakan untuk mengevaluasi peringkasan dokumen (Lin, 2004).

Terdapat beberapa jenis pengukuran dengan menggunakan ROUGE. Dalam penelitian ini akan digunakan 3 jenis pengukuran yaitu ROUGE-N, ROUGE-L, dan ROUGE-SU. Pengukuran ROUGE-N didasarkan pada kemunculan secara statistik dari *n-gram* (*N-gram Co-Occurrence Statistics*). Secara formal, ROUGE-N adalah nilai recall dari *n-gram* yang ada pada kandidat ringkasan terhadap *Groundtruth*. Perhitungan ROUGE-N yang diadopsi dari perhitungan (Lin, 2004) ditunjukkan pada Persamaan (3.9):

$$ROUGE - N = \frac{\sum_{S \in \text{Summ}_{ref}} \sum_{N\text{-gram} \in S} \text{Count}_{match}(N\text{-gram})}{\sum_{S \in \text{Summ}_{ref}} \sum_{N\text{-gram} \in S} \text{Count}(N\text{-gram})}. \quad (3.9)$$

Dimana,

- N : panjang dari *N-gram*
- $\text{Count}_{match}(N\text{-gram})$: jumlah maksimum dari *N-gram* yang muncul pada ringkasan kandidat dan ringkasan sebagai referensi.
- $\text{Count}(N\text{-gram})$: jumlah dari *N-gram* pada ringkasan sebagai referensi

Dimana *n* merepresentasikan panjang dari *n-gram*. Sedangkan count_{match} adalah jumlah *n-gram* yang sama antara *n-gram* dari ringkasan oleh sistem dengan *n-gram* yang ada pada *Groundtruth*. Dengan penyebut dari persamaan tersebut merupakan jumlah total *n-gram* yang ada pada ringkasan referensi.

Penelitian ini menggunakan 4 fungsi ROUGE dari 3 jenis ROUGE dari penelitian (Lin, 2004) yaitu,

- ROUGE-1 : Pengukuran kualitas hasil ringkasan dengan menghitung unit-unit yang overlap pada rangkaian kata yang terdiri dari 1 kata (*unigram*) antara ringkasan system dengan ringkasan referensi (*groundtruth*)
- ROUGE-2 : Pengukuran kualitas hasil ringkasan dengan menghitung unit-unit yang overlap pada rangkaian kata yang terdiri dari 2 kata (*bigram*) antara ringkasan system dengan ringkasan referensi (*groundtruth*)
- ROUGE-L : Pengukuran *Longest Common Subsequence* berdasarkan statistik, dimana pengukuran berdasarkan rangkaian kata terpanjang yang similar antara ringkasan referensi dengan ringkasan system.
- ROUGE-SU4 : Pengukuran kualitas hasil ringkasan dengan skip-bigram dengan penambahan statistik *co-occurrence* berbasis *unigram*.

Berdasarkan penelitian penelitian (Lin, 2004), untuk evaluasi ringkasan multi-dokumen ROUGE-1, ROUGE-2, ROUGE-L dan ROUGE-SU4 memiliki performa yang baik. Oleh karena itu penelitian ini menggunakan keempat fungsi evaluasi tersebut dengan tiga pengukuran yaitu *recall*, *precision*, dan *f-score*. Dimana *recall* adalah tingkat keberhasilan system dalam menemukan kembali (*retrieve*) bagian dari dokumen yang relevan. *Recall* dapat mengacu pada persamaan 3.10.

$$recall = \frac{\text{Jumlah term yang sama antara groundtruth dengan sistem}}{\text{jumlah term pada groundtruth}} \quad (3.10)$$

Sedangkan *precision* adalah tingkat ketepatan antara informasi yang diminta dengan jawaban yang diberikan oleh system. *Precision* dapat mengacu pada persamaan 3.11

$$precision = \frac{\text{Jumlah term yang sama antara groundtruth dengan sistem}}{\text{jumlah term pada ringkasan sistem}} \quad (3.11)$$

F-score merupakan ukuran akurasi suatu tes dengan mempertimbangkan antara *precision* dan *recall* untuk menghitung skor. *F-score* adalah rata-rata harmonik dari *precision* dan *recall*, di mana *f-score* mencapai nilai optimum pada angka 1 dan minimum pada angka 0. *F-score* dapat mengacu pada persamaan 3.12.

$$F - score = 2 \frac{precision*recall}{precision+recall} \quad (3.12)$$

Pengukuran *recall*, *precision* dan *f-score* pada metode evaluasi ROUGE dapat dijadikan paku kualitas hasil suatu ringkasan. Dimana hasil evaluasi dengan nilai tertinggi dari setiap fungsi menunjukkan kualitas hasil ringkasan yang terbaik.

[Halaman ini sengaja dikosongkan]

BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini dipaparkan hasil ujicoba dari penelitian yang telah dilakukan terkait dengan peringkasan multi dokumen berita menggunakan metode pembobotan berdasarkan fitur berita, informasi gramatikal, dan relevansi kalimat terhadap judul.

4.1. Lingkungan Implementasi

Spesifikasi perangkat keras yang digunakan dalam implementasi adalah prosesor Intel Core i3-2330M dengan *clockspeed* 2.20 GHz, dan 8GB RAM. Sistem operasi yang digunakan adalah Microsoft Windows 10 Pro 64-bit. Sedangkan bahasa pemrograman yang digunakan untuk proses peringkasan menggunakan PHP, Python, SQL dan Java. Sistem menggunakan database MySQL untuk menyimpan data artikel, *groundtruth*, dan perhitungan-perhitungan yang telah dilakukan.

4.2. Dataset Ujicoba

Dataset ujicoba yang digunakan pada penelitian ini berasal dari dataset berita dari penelitian (Hayatin et al., 2015) dengan 11 topik yang berbeda. Topik-topik yang dipakai yaitu “*air asia*”, “*banjarnegara*”, “*BBM*”, “*bpjs*”, “*dolly*”, “*pilpres*”, “*ebola*”, “*kurikulum 2013*”, “*sinabung*”, “*palestina*”, dan “*u19*”. Dimana total dataset sebanyak 140 berita. Lebih detail tentang jumlah dari dataset ujicoba per-topik dan total dataset ujicoba yang digunakan ditunjukkan oleh Tabel 4.1.

Tabel 4.1 Dataset ujicoba

No	Topik	Jumlah Artikel	Total Kalimat
1	Air-Asia	7	88
2	Banjarnegara	15	195
3	BBM	12	204

4	BPJS	17	295
5	Dolly	9	180
6	Ebola	7	86
7	Kurikulum 2013	23	403
8	Palestina	17	186
9	Pilpres	18	231
10	Sinabung	6	87
11	U19	9	142
Total:		140	2.097

Dataset ujicoba yang akan diproses telah disimpan dalam format txt dan akan dikonversi menjadi format xml. Pengkonversian dari format txt ke xml dilakukan untuk kemudahan proses pembacaan, keseragaman, dan dapat digunakan kembali untuk penelitian sejenis yang akan datang. Adapun format xml yang digunakan pada dataset ujicoba adalah sebagai berikut:

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<artikel xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance">
  <id> </id>
  <topik> </topik>
  <judul> </judul>
  <tanggal> </tanggal>
  <isi> </isi>
  <link> </link>
</artikel>
```

Tag `<id></id>` digunakan untuk menyimpan *id* artikel berita; `<topik></topik>` digunakan untuk menyimpan nama topik dari artikel berita; `<judul></judul>` digunakan untuk menyimpan judul artikel berita; `<tanggal></tanggal>` digunakan untuk menyimpan tanggal publikasi artikel berita; `<isi></isi>` digunakan untuk menyimpan isi atau konten dari artikel berita; `<link></link>` digunakan untuk menyimpan link atau tautan alamat artikel berita.

4.3. Dataset *Groundtruth*

Dataset *groundtruth* yang akan digunakan juga mengacu pada penelitian sebelumnya. Dimana terdapat 3 varian *groundtruth* untuk tiap topik berita. *Groundtruth* diambil berdasarkan hasil dari ringkasan manual yang telah dilakukan oleh pakar. Adapun detail dataset *groundtruth* untuk tiap topik berita dapat dilihat pada Tabel 4.2.

Tabel 4.2 Dataset *groundtruth* tiap topik berita

No	Topik	Total Kalimat		
		<i>Groundtruth 1</i>	<i>Groundtruth 2</i>	<i>Groundtruth 3</i>
1	Air-Asia	13	54	15
2	Banjarnegara	10	52	15
3	BBM	10	66	15
4	BPJS	14	60	14
5	Dolly	11	68	15
6	Ebola	10	41	15
7	Kurikulum 2013	12	44	12
8	Palestina	7	43	12
9	Pilpres	7	65	16
10	Sinabung	8	41	13
11	U19	9	37	13
Total:		111	571	155

Dataset *groundtruth* yang akan diproses telah disimpan dalam format txt dan akan dikonversi menjadi format xml. Adapun format xml yang digunakan pada dataset *groundtruth* adalah sebagai berikut:

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<artikel xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance">
  <groundtruth> </ groundtruth >
  <topik> </topik>
  <ringkasan> </ringkasan>
</artikel>
```

Tag `<groundtruth>` digunakan untuk menyimpan variasi *groundtruth*; `<topik>` digunakan untuk menyimpan nama topik dari artikel berita; `<ringkasan>` digunakan untuk menyimpan ringkasan manual yang dilakukan oleh pakar.

4.4. Training Parameter dan Penentuan Pengambilan Kalimat Representatif

Training parameter dilakukan untuk memperoleh kombinasi parameter yang optimal yang akan digunakan pada proses peringkasan. Parameter yang optimal dapat meningkatkan kualitas hasil ringkasan. Parameter yang perlu dilakukan *training* adalah bobot label dari *part of speech tagging* dan penentuan pengambilan kalimat *representative*.

Proses *training* dilakukan dua kali dengan memberikan inialisasi awal parameter bobot label POS pada setiap proses *training*. Inialisasi awal nilai parameter bobot label POS untuk *training* pertama didapatkan berdasarkan Jespersen's Rank Theory seperti yang ditunjukkan Tabel 3.10. Sedangkan untuk *training* kedua didapatkan dengan melakukan eksperimen mengenai penghitungan frekuensi kemunculan kata penting pada suatu kalimat. Eksperimen melibatkan 40 dokumen dengan total 639 kalimat. Detail mengenai eksperimen untuk *training* kedua dapat dilihat pada Tabel 4.3.

Tabel 4.3 Eksperimen penentuan bobot label POS

No	Label POS	Total Kemunculan	Total Kata Penting	Bobot
1	Noun	17.318	2.705	0.15620
2	Verb	5.282	722	0.13669
3	Adverb	2.910	347	0.11924
4	Other	10.862	1.367	0.12585

Dari Jespersen's Rank Theory dan eksperimen mengenai penentuan bobot label POS didapatkan nilai-nilai label POS untuk dua *training* yang akan dilakukan. Nilai parameter-parameter untuk dua *training* yang akan dilakukan dapat dilihat seperti Tabel 4.4.

Tabel 4.4 Nilai parameter yang digunakan untuk *training*

<i>Training</i>	Bobot label POS			
	<i>Noun (nn)</i>	<i>Verb (vb)</i>	<i>Adverb (ad)</i>	<i>Other (ot)</i>
1	1	0.75	0.5	0.25
2	0.1562	0.13669	0.11924	0.12585

Training pertama (*training-1*) dan *training* kedua (*training-2*) dilakukan terhadap 4 topik dari dataset yang telah ada yaitu topik “BBM”, “BPJS”, “Kurikulum 2013”, dan “*pilpres*”. Selanjutnya dilakukan *training* untuk penentuan pengambilan kalimat *representative* yaitu *local-representative* dan *global-representative*. *Local-representative* adalah cara penentuan kalimat *representative* dengan mengambil kalimat yang memiliki bobot tertinggi ditiap dokumen pada satu topik. Sedangkan *global-representative* adalah cara penentuan kalimat *representative* dengan mengambil kalimat yang memiliki bobot tertinggi dalam satu topik. *Training* terhadap *local-representative* dan *global-representative* dilakukan untuk mengetahui teknik mana yang memberikan hasil dengan nilai yang tinggi dan nantinya akan diaplikasikan kedalam system.

Training-1 dilakukan menggunakan nilai parameter sesuai dengan Tabel 4.4 yaitu dengan memasukkan bobot label POS {1, 0.75, 0.5, 0.25} pada prosesnya. Hasil untuk *training-1* pada keempat topik dapat dilihat seperti pada Tabel 4.5. Sebagai penjelasan tambahan untuk tiap-tiap table mulai dari Tabel 4.5 keatas, nilai bobot yang ditebalkan (**bold**) pada tiap fungsi (*recall*, *precision*, *f-score*) adalah nilai bobot yang memiliki bobot lebih tinggi daripada yang lain.

Tabel 4.5 Hasil *training-1* untuk empat topik

Topik	ROUGE	Teknik	Recall	Precision	F-Score
BBM	ROUGE-1	Global	0.41640	0.55859	0.47713
		Local	0.45784	0.57869	0.51122
	ROUGE-2	Global	0.24786	0.35546	0.29206
		Local	0.28144	0.37139	0.32022
	ROUGE-L	Global	0.37058	0.47183	0.41512
		Local	0.40047	0.50463	0.44656
ROUGE-SU4	Global	0.26791	0.38083	0.31454	
	Local	0.30061	0.39414	0.34108	
BPJS	ROUGE-1	Global	0.43210	0.62041	0.50941

		Local	0.42740	0.57484	0.49028
	ROUGE-2	Global	0.28755	0.43290	0.34557
		Local	0.25755	0.35989	0.30024
	ROUGE-L	Global	0.37618	0.49655	0.42807
		Local	0.34222	0.42949	0.38092
	ROUGE-SU4	Global	0.31433	0.46206	0.37414
		Local	0.29270	0.39803	0.33734
Kurikulum 2013	ROUGE-1	Global	0.41266	0.56229	0.47599
		Local	0.41266	0.56229	0.47599
	ROUGE-2	Global	0.21376	0.28315	0.24361
		Local	0.21376	0.28315	0.24361
	ROUGE-L	Global	0.31741	0.47940	0.38194
		Local	0.31741	0.47940	0.38194
	ROUGE-SU4	Global	0.25936	0.34406	0.29577
		Local	0.25936	0.34406	0.29577
Pilpres	ROUGE-1	Global	0.43040	0.46012	0.44477
		Local	0.41946	0.45192	0.43509
	ROUGE-2	Global	0.26473	0.29355	0.27840
		Local	0.22738	0.25788	0.24167
	ROUGE-L	Global	0.38101	0.43035	0.40418
		Local	0.40457	0.42254	0.41336
	ROUGE-SU4	Global	0.29062	0.32290	0.30591
		Local	0.26370	0.29881	0.28016

Global : *Global-representative*

Local : *Local-representative*

Tabel 4.5 menunjukkan perbedaan antara teknik penentuan pengambilan kalimat *representative*. Perbedaan teknik *global-representative* maupun *local-representative* tidak terlalu signifikan, malah menghasilkan nilai yang sama untuk evaluasi ROUGE-1, ROUGE-2, ROUGE-L maupun ROUGE-SU4 seperti pada topik “kurikulum 2013”. Akan tetapi untuk topik lainnya hasil dari kedua teknik pengambilan kalimat *representative* dapat berbeda. Untuk detail rata-rata hasil evaluasi ROUGE menggunakan dua teknik dapat mengacu pada Tabel 4.6.

Tabel 4.6 Rata-rata hasil evaluasi ROUGE untuk *training-1*

ROUGE	Teknik	Recall	Precision	F-score
ROUGE-1	Global	0.42289	0.55035	0.47683
	Local	0.42934	0.54194	0.47814
ROUGE-2	Global	0.25348	0.34127	0.28991
	Local	0.24503	0.31808	0.27643
ROUGE-L	Global	0.36129	0.46953	0.40733

	Local	0.36617	0.45902	0.40569
ROUGE-SU4	Global	0.28306	0.37746	0.32259
	Local	0.27909	0.35876	0.31359

Tabel 4.6 menunjukkan rata-rata nilai ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4 pada kedua teknik penentuan pengambilan kalimat *representative*. Teknik *global-representative* memiliki rata-rata ROUGE untuk *recall*, *precision*, *f-score* secara berturut-turut adalah 0.33018, 0.43465, 0.37416. Sedangkan teknik *local-representative* memiliki rata-rata nilai 0.32991, 0.41945, 0.36847. Teknik *global-representative* sedikit lebih unggul dibandingkan *local-representative* dengan selisih untuk *recall*, *precision*, *f-score* adalah 0.00027, 0.0152, 0.00569.

Training kedua (*training-2*) dilakukan dengan memasukkan parameter *training-2* untuk bobot label POS {0.1562, 0.13669, 0.11924, 0.12585} pada saat proses. Bobot label POS yang diperoleh adalah hasil dari eksperimen secara manual dalam menentukan kata-kata penting pada suatu kalimat. Untuk hasil dari *training-2* dapat dilihat pada Tabel 4.7

Tabel 4.7 Hasil *training-2* untuk empat topik

Topik	ROUGE	Teknik	Recall	Precision	F-Score	
BBM	ROUGE-1	Global	0.42106	0.54088	0.47351	
		Local	0.45784	0.57869	0.51122	
	ROUGE-2	Global	0.24136	0.31867	0.27467	
		Local	0.28144	0.37139	0.32022	
	ROUGE-L	Global	0.35613	0.45626	0.40002	
		Local	0.40047	0.50463	0.44656	
	ROUGE-SU4	Global	0.26442	0.3478	0.30043	
		Local	0.30061	0.39414	0.34108	
	BPJS	ROUGE-1	Global	0.42540	0.56592	0.48570
			Local	0.41379	0.48735	0.44757
ROUGE-2		Global	0.29079	0.38583	0.33163	
		Local	0.26117	0.30681	0.28215	
ROUGE-L		Global	0.36445	0.45238	0.40368	
		Local	0.34595	0.38068	0.36249	
ROUGE-SU4		Global	0.31705	0.41750	0.36041	
		Local	0.29258	0.33697	0.31321	
Kurikulum 2013	ROUGE-1	Global	0.39675	0.55965	0.46433	
		Local	0.39675	0.55965	0.46433	

Pilpres	ROUGE-2	Global	0.21274	0.29213	0.24619
		Local	0.21274	0.29213	0.24619
	ROUGE-L	Global	0.30651	0.46591	0.36976
		Local	0.30651	0.46591	0.36976
	ROUGE-SU4	Global	0.25378	0.35141	0.29472
		Local	0.25378	0.35141	0.29472
	ROUGE-1	Global	0.41849	0.44513	0.43140
		Local	0.41913	0.44619	0.43224
	ROUGE-2	Global	0.22819	0.25817	0.24226
		Local	0.23165	0.25853	0.24435
	ROUGE-L	Global	0.37254	0.39627	0.38404
		Local	0.39476	0.41315	0.40375
ROUGE-SU4	Global	0.26350	0.29494	0.27834	
	Local	0.26505	0.29501	0.27922	

Tabel 4.7 menunjukkan hasil yang sama untuk kedua teknik penentuan pengambilan kalimat *representative* pada topik “Kurikulum 2013”. Untuk detail rata-rata hasil dari *training-2* dapat dilihat pada table 4.8.

Tabel 4.8 Rata-rata hasil evaluasi ROUGE untuk *training-2*

ROUGE	Teknik	Recall	Precision	F-score
ROUGE-1	Global	0.41542	0.52790	0.46373
	Local	0.42188	0.51797	0.46384
ROUGE-2	Global	0.24327	0.31370	0.27369
	Local	0.24675	0.30721	0.27323
ROUGE-L	Global	0.34991	0.44270	0.38938
	Local	0.36192	0.44109	0.39564
ROUGE-SU4	Global	0.27469	0.35291	0.30848
	Local	0.27801	0.34438	0.30706

Tabel 4.8 menunjukkan rata-rata nilai ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4 untuk *training-2*. Teknik *global-representative* memiliki rata-rata ROUGE untuk *recall*, *precision*, *f-score* secara berturut-turut adalah 0.32082, 0.4093, 0.35882. Sedangkan teknik *local-representative* memiliki rata-rata nilai 0.32714, 0.40267, 0.35994. Untuk *training-2*, teknik *local-representative* sedikit lebih unggul dibandingkan dengan *global-representative* pada hasil *recall* dan *f-score* dengan selisih 0.00632 dan 0.00112. Sedangkan untuk *precision* *global-representative* lebih unggul daripada *local-representative* dengan selisih 0.00663.

Parameter optimal yang akan dipakai dalam metode pembobotan kalimat dalam peringkatan multi-dokumen berita adalah parameter yang memberikan hasil yang paling optimum (paling tinggi) antara *training-1* dan *training-2*. Untuk mengetahui hasil akhir *training-1* dan *training-2* dapat mengacu pada Tabel 4.9.

Tabel 4.9 Perbandingan hasil *training-1* dengan *training-2*

Training	Teknik	Avg. Recall	Avg. Precision	Avg. F-score
1	Global	0.33018	0.43465	0.37416
	Local	0.32991	0.41945	0.36847
2	Global	0.32082	0.40930	0.35882
	Local	0.32714	0.40267	0.35994

Tabel 4.10 Peningkatan hasil evaluasi *training-1* terhadap *training-2*

Teknik	Recall	Precision	F-Score
Global	0.00936 (↑ 2.92%)	0.02535 (↑ 6.19%)	0.01534 (↑ 4.28%)
Local	0.00277 (↑ 0.85%)	0.01678 (↑ 4.17%)	0.00853 (↑ 2.37%)

Dari keseluruhan rata-rata untuk *recall*, *precision*, dan *f-score* yang ditunjukkan Tabel 4.9 dapat disimpulkan bahwa parameter pada *training-1* dengan *global-representative* memiliki nilai rata-rata yang paling tinggi diantara yang lain. Berdasarkan Tabel 4.10 parameter *training-1* memiliki hasil yang lebih dibandingkan parameter pada *training-2* dengan peningkatan untuk teknik *global-representatif* sebesar 2.92% (*recall*), 6.19% (*precision*), 4.28% (*f-score*). Sedangkan untuk teknik *local-representatif* sebesar 0.85% (*recall*), 4.17% (*precision*), 2.37% (*f-score*). Sehingga untuk sistem peringkatan multi-dokumen berita berbahasa Indonesia, akan digunakan parameter yang mengikuti *training-1* yaitu dengan memasukkan bobot label POS untuk *noun (nn)*, *verb (vb)*, *adverb (ad)*, dan *other (ot)* secara berturut-turut adalah 1, 0.75, 0.5, 0.25 dan menggunakan teknik pengambilan kalimat *global-representative*.

4.5. Ujicoba dan Analisis Hasil Ringkasan

Pada sub-bab ini dipaparkan ujicoba dan analisis hasil dari sistem peringkatan dengan metode yang diusulkan yaitu pembobotan dari fitur berita dengan pendekatan informasi gramatikal dan relevansi kalimat terhadap judul (NeFGISR)

dan dibandingkan dengan hasil ringkasan dengan metode pembobotan dari fitur berita dengan pendekatan *trending issue* (NeFTIS). Pengukuran performa kedua metode tersebut menggunakan evaluasi ROUGE, diantaranya ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4.

4.4.1. Ujicoba 1: Analisis Hasil Ringkasan Metode Usulan

Tujuan dari ujicoba 1 adalah untuk menerapkan hasil dari *training* parameter terhadap penelitian dengan metode yang diusulkan yaitu pembobotan kalimat berdasarkan fitur berita dengan pendekatan informasi gramatikal dan relevansi kalimat terhadap judul (NeFGISR). Hasil dari *training* parameter akan dijadikan parameter inisialisasi pada sistem untuk melakukan proses peringkasan multi-dokumen berita.

Parameter yang digunakan pada NeFGISR adalah parameter bobot label POS dengan nilai *noun* = 1, *verb* = 0.75, *adverb* = 0.5, *other* = 0.25. Sedangkan teknik penentuan pengambilan kalimat *representative* yang dipakai adalah *global sentence*. Ujicoba 1 dilakukan pada 11 topik dan hasil ringkasan diperoleh dengan cara mengambil 10 kalimat ($n = 10$) yang memiliki bobot paling tinggi di tiap topik sebagai kalimat *representative*. Hasil ringkasan kemudian akan dibandingkan dengan 3 varian *groundtruth* yang ada pada setiap topik. Hasil dari ujicoba 1 dapat diketahui seperti pada Tabel 4.11.

Tabel 4.11 Hasil ujicoba 1 untuk $n = 10$

Topik	ROUGE	Recall	Precision	F-score
Air-Asia	ROUGE-1	0.50454	0.61382	0.55384
	ROUGE-2	0.40050	0.47475	0.43448
	ROUGE-L	0.40960	0.56667	0.47550
	ROUGE-SU4	0.42551	0.49722	0.45858
Banjarnegara	ROUGE-1	0.50837	0.55455	0.53046
	ROUGE-2	0.36582	0.40212	0.38311
	ROUGE-L	0.48439	0.59817	0.53530
	ROUGE-SU4	0.38787	0.42089	0.40371
BBM	ROUGE-1	0.41640	0.55859	0.47713
	ROUGE-2	0.24786	0.35546	0.29206
	ROUGE-L	0.37058	0.47183	0.41512
	ROUGE-SU4	0.26791	0.38083	0.31454
BPJS	ROUGE-1	0.43210	0.62041	0.50941

	ROUGE-2	0.28755	0.4329	0.34557
	ROUGE-L	0.37618	0.49655	0.42807
	ROUGE-SU4	0.31433	0.46206	0.37414
Dolly	ROUGE-1	0.50699	0.59296	0.54661
	ROUGE-2	0.38175	0.44907	0.41268
	ROUGE-L	0.46073	0.54525	0.49944
	ROUGE-SU4	0.40943	0.47448	0.43956
Ebola	ROUGE-1	0.51767	0.58741	0.55034
	ROUGE-2	0.32926	0.39975	0.36110
	ROUGE-L	0.49208	0.53209	0.51130
	ROUGE-SU4	0.36900	0.43646	0.39991
Kurikulum 2013	ROUGE-1	0.41266	0.56229	0.47599
	ROUGE-2	0.21376	0.28315	0.24361
	ROUGE-L	0.31741	0.47940	0.38194
	ROUGE-SU4	0.25936	0.34406	0.29577
Palestina	ROUGE-1	0.48915	0.54058	0.51358
	ROUGE-2	0.33710	0.36850	0.35210
	ROUGE-L	0.37084	0.46246	0.41161
	ROUGE-SU4	0.36757	0.40032	0.38325
Pilpres	ROUGE-1	0.43040	0.46012	0.44477
	ROUGE-2	0.26473	0.29355	0.27840
	ROUGE-L	0.38101	0.43035	0.40418
	ROUGE-SU4	0.29062	0.32290	0.30591
Sinabung	ROUGE-1	0.45043	0.56597	0.50163
	ROUGE-2	0.33999	0.44848	0.38678
	ROUGE-L	0.41812	0.50505	0.45749
	ROUGE-SU4	0.35733	0.46667	0.40474
U19	ROUGE-1	0.44610	0.58188	0.50502
	ROUGE-2	0.25694	0.37713	0.30564
	ROUGE-L	0.28248	0.37931	0.32381
	ROUGE-SU4	0.29195	0.41558	0.34296

Tabel 4.11 menunjukkan hasil evaluasi ROUGE untuk kesebelas topik dari dataset. Hasil ringkasan didapat dari pembobotan kalimat dengan menggunakan persamaan 3.8. Sample pembobotan kalimat menggunakan metode NeFGISR pada topik “*pilpres*” seperti pada Tabel 4.12. Topik “*pilpres*” dipilih karena mengacu pada metode sebelumnya (NeFTIS) bahwa topik “*pilpres*” adalah topik yang memiliki skenario dan ringkasan terbaik dari topik lainnya.

Tabel 4.12 Sampel Pembobotan Kalimat dengan NeFGISR untuk topik “pilpres”

<i>Doc</i>	<i>Pos</i>	W_1	W_2	W_3	W_4	W_5	W_6	W_7	<i>score</i>
9	1	0.5981	1.1477	1	0.6651	0.6651	0.1654	0	3.0159
12	1	0.4573	1.0213	1	0.4393	0.4393	0.3124	0	2.6589
8	1	0.5391	0.9989	1	0.5980	0.5980	0.1812	0	2.5846
17	1	0.4827	1.0411	1	0.6061	0.6061	0.1365	0	2.5773
14	1	0.5036	1.0304	1	0.4810	0.4810	0.1624	0	2.5466
3	1	0.3650	1.0404	1	0.4505	0.4505	0.1355	0	2.4759
4	2	0.7487	1.2522	0.7071	0.4613	0.4613	0.0244	0.006	2.3585
2	1	0.4996	0.9461	1	0.3979	0.3979	0.0677	0.0198	2.3509
6	1	0.3553	0.9712	1	0.4444	0.4444	0.0942	0.0671	2.3425
1	1	0.5727	0.9928	1	0.4480	0.4480	0.0800	0	2.3298

Tabel 4.12 adalah sampel untuk topik “pilpres” berupa pembobotan dari 10 kalimat untuk masing-masing fitur beserta total bobot (*score*) kalimat menggunakan metode pembobotan NeFGISR. Dimana variabel *doc* merupakan *id* dokumen berita dan *pos* menunjukkan posisi kalimat pada dokumen *doc*. Untuk menghitung total bobot atau skor, NeFTGISR menggunakan persamaan 3.8, penjelasan lebih detail tentang penghitungan total bobot dengan NeFGISR dapat dilihat pada subbab 3.3.3.

Pada Tabel 4.12 diketahui untuk sampel topik “pilpres” pembobotan berdasarkan posisi kalimat (W_3) dengan nilai 1 yaitu kalimat berada tepat pada awal dokumen mendominasi akan penentuan kalimat *representative*. Hal ini sesuai dengan pendapat (Verdianto et al., 2016) menyatakan bahwa sebagian besar berita cenderung menyampaikan ide pokoknya pada awal-awal kalimat sedangkan kalimat-kalimat selanjutnya merupakan penjelas atau bahkan informasi-informasi lain di luar pokok bahasan.

Hasil ringkasan dari NeFGISR pada sampel topik “pilpres” akan dibandingkan dengan tiga varian *groundtruth* dari topik yang sama. Tabel 4.13 menunjukkan hasil ringkasan dari metode yang diusulkan yaitu NeFGISR dan salah satu varian *groundtruth* untuk topik “pilpres” yaitu *groundtruth-3*.

Tabel 4.13 Hasil ringkasan NeFGISR dan *groundtruth* untuk topik “pilpres”

NeFGISR	Groundtruth-3
<p>Komisi Pemilihan Umum (KPU) Kota Bogor membuka kembali kotak suara pemilihan presiden 2014. Sebanyak 98 kotak suara dalam Pemilihan Presiden (Pilpres) di Kabupaten Pamekasan, Madura, Jawa Timur, dibongkar oleh KPUD setempat.</p> <p>Enam kotak suara Pemilu Presiden 2014 di Kabupaten Ponorogo, Jawa Timur, diketahui tidak dilengkapi dokumen C1 dan D1 yang berisi hasil penghitungan suara tingkat TPS dan PPS.</p> <p>Komisi Pemilihan Umum (KPU) Kota Medan melakukan pembukaan kotak suara di gudang penyimpanan, Jalan Budi Kemasyarakatan, Medan, Ahad (10/8/2014).</p> <p>Kotak suara pada 63 tempat pemungutan suara (TPS) di Komisi Pemilihan Umum (KPU) Kota Sukabumi dan 278 TPS di KPU Kabupaten Sukabumi, Jawa Barat dibongkar oleh Komisioner KPU.</p> <p>Pasangan capres Prabowo-Hatta telah mengajukan gugatan hasil pilpres 2014 ke Mahkamah Konstitusi (MK). Hasilnya, mayoritas pemilih menjawab pilpres berlangsung bebas dan jujur, hanya 2,3 persen menilai pilpres tidak bebas dan tidak jujur.</p> <p>Langkah pasangan Prabowo Subianto-Hatta Rajasa mengajukan permohonan hasil pemilihan umum (PHPU) ke Mahkamah Konstitusi tidak didukung oleh pemilihnya sendiri.</p> <p>Tim Penasehat Hukum pasangan Prabowo Subianto-Hatta Rajasa meminta majelis hakim Mahkamah Konstitusi (MK) mengabulkan permohonan untuk menetapkan pasangan nomor urut 1 sebagai presiden dan wakil presiden terpilih pada Pilpres 2014.</p> <p>Sikap capres Prabowo Subianto dan para elite pendukungnya yang</p>	<p>Survei Saiful Mujani Research Consulting (SMRC) merilis hasil survei di 33 provinsi pasca pilpres kepada pemilih.</p> <p>Direktur Riset SMRC Dr Djayadi Hanan, mengatakan, klaim kecurangan yang disuarakan oleh Prabowo bisa dianggap sebagai pihak yang gagal move on dengan hasil Pemilu.</p> <p>Karenanya berdasarkan data survei SMRC, hasil pemilu yang diumumkan KPU masyarakat sudah merasa puas.</p> <p>Langkah pasangan Prabowo Subianto-Hatta Rajasa mengajukan permohonan hasil pemilihan umum (PHPU) ke Mahkamah Konstitusi tidak didukung oleh pemilihnya sendiri.</p> <p>Hasil survei menunjukkan, 48,2 persen responden menilai pilpres berlangsung sangat bebas dan jujur.</p> <p>"Sikap Prabowo menggugat ke MK karena menganggap pilpres totaliter dan penuh kecurangan, tidak didukung oleh mayoritas masyarakat, bahkan pendukungnya sendiri.</p> <p>Dalam diskusi bertema 'Kinerja Demokrasi dan Pilpres 2014' di Hotel Sari Pan Pacific, Jakarta, Minggu (10/8/2014), Direktur Riset SMRC Djayadi Hanan, menyatakan, secara umum masyarakat puas dengan pelaksanaan pilpres.</p> <p>"Sebanyak 77,9 persen pemilih nasional menilai bahwa pilpres yang baru dilaksanakan itu berlangsung dengan bebas dan jujur," katanya.</p> <p>"Prabowo yang menilai pilpres seperti di negara totalitarian atau fasis atau komunis di mana kebebasan dan kejujuran politik tidak ada," kata Djayadi yang termasuk di antara 2,3 persen warga itu.</p> <p>Saiful Mujani Research Consulting (SMRC) menggelar survei bertajuk 'Kinerja Demokrasi dan Pilpres 2014'.</p> <p>Salah satu hasilnya menunjukkan mayoritas pemilih Indonesia puas dengan hasil Pilpres.</p> <p>"Sebanyak 48,2% pemilih menjawab pilpres sangat bebas dan jujur, 29,7% bebas dan jujur dengan sedikit permasalahan," kata Direktur Riset SMRC Dr.</p> <p>Djayadi Hanan dalam paparan survei di Hotel Sari Pan Pacific, Jl MH Thamrin, Jakarta, Minggu (10/8/2014).</p>

menolak hasil Pilpres 2014 yang ditetapkan KPU pada 22 Juli lalu tidak mencerminkan sikap para pemilih mereka.	Sikap capres Prabowo Subianto dan para elite pendukungnya yang menolak hasil Pilpres 2014 yang ditetapkan KPU pada 22 Juli lalu tidak mencerminkan sikap para pemilih mereka. Direktur Riset SMRC Djayadi Hanan mengatakan, bukan hanya pemilih Jokowi yang menilai Pilpres 2014 berlangsung sangat bebas dan jujur, namun juga penilaian tersebut dilakukan pemilih Prabowo. "Prabowo yang kecewa dengan praktik demokrasi atau dengan Pilpres, menyimpang dari kecenderungan sikap pemilihnya sendiri," kata Djayadi.
--	---

Hasil ringkasan untuk sampel topik “*pilpres*” dibandingkan dengan 3 variasi *groundtruth* secara terpisah. Hal ini dilakukan untuk mengetahui lebih detail seberapa besar tingkat similaritas antara kalimat ringkasan hasil metode NeFGISR dengan *groundtruth* yang ada. Untuk lebih detailnya dapat dilihat pada Tabel 4.14.

Tabel 4.14 Evaluasi hasil ringkasan dengan 3 varian *groundtruth* untuk topik “*pilpres*”

<i>Groundtruth</i>	<i>ROUGE</i>	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
<i>Groundtruth-1</i>	ROUGE-1	0.55906	0.21779	0.31347
	ROUGE-2	0.33333	0.12903	0.18605
	ROUGE-L	0.41111	0.27612	0.33036
	ROUGE-SU4	0.35752	0.13741	0.19853
	Rata-rata	0.41526	0.19009	0.25710
<i>Groundtruth-2</i>	ROUGE-1	0.19489	0.63190	0.29790
	ROUGE-2	0.13407	0.42903	0.20430
	ROUGE-L	0.31048	0.57463	0.40314
	ROUGE-SU4	0.14951	0.47143	0.22703
	Rata-rata	0.19724	0.52675	0.28309
<i>Groundtruth-3</i>	ROUGE-1	0.53727	0.53067	0.53395
	ROUGE-2	0.32680	0.32258	0.32468
	ROUGE-L	0.42143	0.44030	0.43066
	ROUGE-SU4	0.36483	0.35986	0.36233
	Rata-rata	0.41258	0.41335	0.41291

Tabel 4.14 menunjukkan tingkat relevansi hasil ringkasan NeFGISR terhadap *groundtruth*. Berdasarkan tingkat keberhasilan system dalam menemukan kembali bagian dari dokumen yang relevan (*recall*), hasil ringkasan NeFGISR untuk topik “*pilpres*” memiliki tingkat relevansi yang tinggi terhadap *groundtruth*-

1 dengan nilai rata-rata tertinggi untuk fungsi *recall* yaitu 0.41526. Sedangkan berdasarkan tingkat ketepatan antara hasil ringkasan terhadap informasi yang diminta atau *groundtruth* (*precision*), hasil ringkasan NeFGISR cenderung memiliki relasi yang besar terhadap *groundtruth-2* dengan nilai rata-rata *precision* sebesar 0.52675. Untuk *f-score* yaitu pengukuran rata-rata harmonic antara *recall* dan *precision*, hasil ringkasan dari NeFGISR lebih relevan dengan *groundtruth-3* dengan hasil 0.41291.

4.4.2. Ujicoba 2: Perbandingan Performa NeFGISR dengan NeFTIS

Ujicoba 2 dilakukan dengan skenario mengukur performa hasil ringkasan dari metode usulan, yaitu pembobotan kalimat berdasarkan fitur berita dengan pendekatan informasi gramatikal dan relevansi kalimat terhadap judul (NeFGISR) dibandingkan dengan metode pembobotan dari fitur berita dengan pendekatan *Trending Issue* (NeFTIS).

Ujicoba 2 dilakukan dengan menggunakan sampel topik "*pilpres*" untuk kedua metode pembobotan. Pengukuran performa menggunakan 4 perbandingan, yaitu berdasarkan *groundtruth-1*, *groundtruth-2*, *groundtruth-3*, dan gabungan ketiga *groundtruth*. Hasil dari ringkasan antara NeFGISR dan NeFTIS dapat dilihat pada Tabel 4.15.

Tabel 4.15 Hasil ringkasan NeFGISR dan NeFTIS untuk topik "*pilpres*"

NeFGISR	NeFTIS
Komisi Pemilihan Umum (KPU) Kota Bogor membuka kembali kotak suara pemilihan presiden 2014. Sebanyak 98 kotak suara dalam Pemilihan Presiden (Pilpres) di Kabupaten Pamekasan, Madura, Jawa Timur, dibongkar oleh KPUD setempat. Enam kotak suara Pemilu Presiden 2014 di Kabupaten Ponorogo, Jawa Timur, diketahui tidak dilengkapi dokumen C1 dan D1 yang berisi hasil penghitungan suara tingkat TPS dan PPS. Komisi Pemilihan Umum (KPU) Kota Medan melakukan pembukaan kotak suara di gudang penyimpanan, Jalan Budi Kemasyarakatan, Medan, Ahad (10/8/2014).	"Dari 11 pengaduan yang masuk, sebenarnya secara formal masih banyak yang belum memenuhi syarat Tapi secara substansi sudah masuk Pilpres ini sesuatu yang serius, jangan terlalu lama dipendam Makanya jangan sampai hanya karena soal titik koma kemudian kami dismiss (ditolak)," ujar Ketua Majelis DKPP Jimly Asshiddiqie. "Sebanyak 98 kotak suara dari 98 TPS tersebut tersebar pada 13 Kecamatan se-Kabupaten Pamekasan," terang Hamzah pada wartawan saat dikonfirmasi wartawan, Minggu (10/8/2014). Direktur Riset SMRC Dr Djayadi Hanan, mengatakan, klaim kecurangan yang disuarakan oleh Prabowo bisa dianggap

Kotak suara pada 63 tempat pemungutan suara (TPS) di Komisi Pemilihan Umum (KPU) Kota Sukabumi dan 278 TPS di KPU Kabupaten Sukabumi, Jawa Barat dibongkar oleh Komisioner KPU. Pasangan capres Prabowo-Hatta telah mengajukan gugatan hasil pilpres 2014 ke Mahkamah Konstitusi (MK). Hasilnya, mayoritas pemilih menjawab pilpres berlangsung bebas dan jujur, hanya 2,3 persen menilai pilpres tidak bebas dan tidak jujur. Langkah pasangan Prabowo Subianto-Hatta Rajasa mengajukan permohonan hasil pemilihan umum (PHPU) ke Mahkamah Konstitusi tidak didukung oleh pemilihnya sendiri. Tim Penasehat Hukum pasangan Prabowo Subianto-Hatta Rajasa meminta majelis hakim Mahkamah Konstitusi (MK) mengabulkan permohonan untuk menetapkan pasangan nomor urut 1 sebagai presiden dan wakil presiden terpilih pada Pilpres 2014. Sikap capres Prabowo Subianto dan para elite pendukungnya yang menolak hasil Pilpres 2014 yang ditetapkan KPU pada 22 Juli lalu tidak mencerminkan sikap para pemilih mereka.

sebagai pihak yang gagal move on dengan hasil Pemilu. Selain itu, pembukaan kotak suara ini terlihat dikawal ketat oleh pihak kepolisian. Lebih lanjut Arif menjelaskan, dari keseluruhan kotak suara yang dibuka ada kejanggalan. Seperti ditayangkan Liputan 6 Siang SCTV, Minggu (10/8/2014), pembongkaran disaksikan oleh tim Prabowo Subianto-Hatta Rajasa dan Joko Widodo-Jusuf Kalla serta aparat kepolisian di Jalan Otista, Sukabumi. "Ini adalah sebagai tindak lanjut atas dugaan kejanggalan yang disangkakan oleh pihak capres nomor urut 1 (Prabowo-Hatta) kepada kubu Jokowi-JK," papar Undang di Bogor, Sabtu (9/8/2014). Terkait temuan itu, KPU Ponorogo langsung berkonsultasi dengan Bawaslu Jawa Timur. KPUD Majalengka diberi waktu 1 hari untuk melengkap dokumen yang akan dibawa ke sidang Mahkamah Konstitusi (MK). "Jadi elite-elite Gerindra (yang sebut pilpres tidak jujur) masuk minoritas Begitu juga dengan partai lain," imbuh Djayadi.

Ringkasan yang dihasilkan dari metode NeFGISR dan NeFTIS kemudian akan dilakukan evaluasi ROUGE. Hal ini dilakukan untuk mengetahui tingkat similaritas dan kualitas hasil ringkasan NeFGISR dan NeFTIS terhadap *groundtruth*. Evaluasi dilakukan terhadap masing-masing *groundtruth* yang kemudian akan dilakukan terhadap gabungan dari ketiga *groundtruth*.

Tabel 4.16 Hasil evaluasi NeFGISR dan NeFTIS terhadap *groundtruth-1*

ROUGE	NeFGISR			NeFTIS		
	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
ROUGE-1	0.5591	0.2178	0.3135	0.4173	0.2409	0.3055
ROUGE-2	0.3333	0.1290	0.1861	0.2250	0.1286	0.1636
ROUGE-L	0.4111	0.2761	0.3304	0.3889	0.2161	0.2778

ROUGE-SU4	0.3575	0.1374	0.1985	0.2602	0.1470	0.1879
-----------	---------------	--------	---------------	--------	---------------	--------

Tabel 4.16 menunjukkan bahwa NeFGISR memberikan hasil evaluasi ROUGE terhadap *groundtruth-1* lebih tinggi dibandingkan dengan NeFTIS. NeFGISR memiliki nilai yang tinggi daripada NeFTIS pada perhitungan *recall* dan *f-score* untuk ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4. Sedangkan NeFTIS hanya unggul pada perhitungan *precision* untuk ROUGE-1, ROUGE-2, dan ROUGE-SU4.

Tabel 4.17 Hasil evaluasi NeFGISR dan NeFTIS terhadap *groundtruth-2*

ROUGE	NeFGISR			NeFTIS		
	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
ROUGE-1	0.1949	0.6319	0.2979	0.1173	0.5636	0.1942
ROUGE-2	0.1341	0.4290	0.2043	0.0524	0.2476	0.0865
ROUGE-L	0.3105	0.5746	0.4031	0.2823	0.4321	0.3415
ROUGE-SU4	0.1495	0.4714	0.2270	0.0669	0.3100	0.1100

Tabel 4.17 menunjukkan hasil evaluasi NeFGISR unggul secara keseluruhan dibandingkan dengan NeFTIS terhadap *groundtruth-2*. Dimana NeFGISR memiliki nilai yang lebih tinggi daripada NeFTIS untuk perhitungan *recall*, *precision*, dan *f-score* pada evaluasi ROUGE-1, ROUGE-2, ROUGE-L, maupun ROUGE-SU4. Hal ini dapat dikatakan bahwa hasil ringkasan dari NeFGISR lebih relevan dibandingkan dengan hasil ringkasan NeFTIS.

Tabel 4.18 Hasil evaluasi NeFGISR dan NeFTIS terhadap *groundtruth-3*

ROUGE	NeFGISR			NeFTIS		
	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
ROUGE-1	0.5373	0.5307	0.5340	0.2826	0.4136	0.3358
ROUGE-2	0.3268	0.3226	0.3247	0.1209	0.1762	0.1434
ROUGE-L	0.4214	0.4403	0.4307	0.3357	0.2901	0.3113
ROUGE-SU4	0.3648	0.3599	0.3623	0.1503	0.2180	0.1780

Tabel 4.19 Hasil evaluasi NeFGISR dan NeFTIS terhadap ketiga groundtruth

ROUGE	NeFGISR			NeFTIS		
	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
ROUGE-1	0.4304	0.4601	0.4448	0.2724	0.4061	0.3261
ROUGE-2	0.2647	0.2936	0.2784	0.1328	0.1841	0.1543
ROUGE-L	0.3810	0.4304	0.4042	0.3356	0.3128	0.3238
ROUGE-SU4	0.2906	0.3229	0.3059	0.1591	0.2250	0.1864

Tabel 4.18 menunjukkan NeFGISR memiliki hasil yang lebih tinggi dibandingkan dengan NeFTIS secara keseluruhan pada *groundtruth-3*. Begitupula pada Tabel 4.19 yang menunjukkan NeFGISR unggul dalam evaluasi terhadap ketiga *groundtruth*. Metode NeFGISR mencapai hasil yang lebih baik dibandingkan NeFTIS dengan peningkatan nilai *recall* untuk ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4 secara berturut-turut adalah 0.158 (58%), 0.1319 (99.32%), 0.0454 (13.53%), 0.1315 (82.65%). Untuk lebih detailnya bias melihat pada Tabel 4.20.

Tabel 4.20 Peningkatan hasil evaluasi NeFGISR terhadap NeFTIS untuk topik “*pilpres*”

ROUGE	<i>Recall</i>	<i>Precision</i>	<i>F-Score</i>
ROUGE-1	0.1580 (↑ 58.00%)	0.0540 (↑ 13.30%)	0.1187 (↑ 36.40%)
ROUGE-2	0.1319 (↑ 99.32%)	0.1095 (↑ 59.48%)	0.1241 (↑ 80.43%)
ROUGE-L	0.0454 (↑ 13.53%)	0.1176 (↑ 37.60%)	0.0804 (↑ 24.83%)
ROUGE-SU4	0.1315 (↑ 82.65%)	0.0979 (↑ 43.51%)	0.1195 (↑ 64.11%)
Rata-rata	0.1167 (↑ 63.38%)	0.0948 (↑ 38.47%)	0.1107 (↑ 51.44%)

Adapun evaluasi terhadap jumlah kata hasil ringkasan NeFGISR dan NeFTIS terhadap *groundtruth* dilakukan untuk mengetahui perbandingan jumlah term yang ada pada hasil ringkasan NeFGISR, NeFTIS maupun pada *groundtruth*. Perbandingan jumlah term dapat dilihat seperti Table 4.21.

Tabel 4.21 Jumlah *term* pada hasil ringkasan untuk topik “*pilpres*”

No	Ringkasan	Jumlah <i>term</i>	<i>Term unik</i>
1	NeFGISR	218	111

2	NeFTIS	220	170
3	<i>Groundtruth-1</i>	127	95
4	<i>Groundtruth-2</i>	1049	287
5	<i>Groundtruth-3</i>	322	151

Tabel 4.22 Jumlah *term* yang sama antara NeFGISR dan NeFTIS terhadap *groundtruth* pada topik “*pilpres*”

Ringkasan	<i>Groundtruth-1</i>	<i>Groundtruth-2</i>	<i>Groundtruth-3</i>
NeFGISR	92	148	135
NeFTIS	79	126	98

Tabel 4.21 menunjukkan jumlah *term* dan jumlah *term* unik hasil ringkasan dari NeFGISR, NeFTIS, dan masing-masing *groundtruth*. Dimana *term* unik adalah *term* yang muncul pada hasil ringkasan dengan mengabaikan frekuensi kemunculan dari *term* itu sendiri. NeFGISR memiliki total 218 *term* dengan 111 *term* unik dan NeFTIS memiliki total 220 *term* dengan 170 *term* unik. Untuk ketiga *groundtruth* yaitu *groundtruth-1*, *groundtruth-2*, dan *groundtruth-3* masing-masing memiliki total 127, 1049, 322 *term* dan memiliki 95, 287, dan 151 *term* unik.

Tabel 4.22 menunjukkan total *term* dari NeFGISR dan NeFTIS yang sama (*overlap*) terhadap *term* yang ada pada masing-masing *groundtruth*. Dimana jumlah *term* yang sama dengan *groundtruth-1*, *groundtruth-2*, *groundtruth-3* untuk NeFGISR secara berturut-turut adalah 92, 148, dan 135. Sedangkan jumlah *term* yang sama untuk NeFTIS terhadap *groundtruth-1*, *groundtruth-2*, *groundtruth-3* adalah 79, 126, dan 98. Dari perbandingan tersebut dapat disimpulkan bahwa performa dari metode yang diusulkan yaitu NeFGISR memiliki kualitas hasil ringkasan lebih baik dibandingkan dengan metode NeFTIS. Hal ini dimungkinkan karena seleksi *term* penting pada metode NeFTIS hanya berdasarkan frekuensi sehingga *term* yang memiliki frekuensi kemunculan tinggi akan dianggap sebagai *term* penting. Padahal ada kemungkinan *term* yang frekuensi kemunculannya kecil juga dapat menjadi *term* penting. Disisi lain NeFGISR menyeleksi *term* berdasarkan fitur berita dengan pendekatan gramatikal informasi dan relevansi kalimat terhadap judul. Sehingga pemilihan *term* penting cakupannya luas, tidak hanya sebatas frekuensi

kemunculannya melainkan juga konten informatif yang dikandungnya dan relasi term tersebut terhadap judul.

BAB 5

KESIMPULAN DAN SARAN

Berdasarkan hasil dan ujicoba, maka dapat ditarik beberapa kesimpulan diantara lain:

1. Parameter pada *training-1* dengan teknik pengambilan kalimat *global-representative* memberikan hasil ringkasan dengan nilai evaluasi ROUGE lebih tinggi dibandingkan dengan yang lain. Adapun parameter tersebut adalah bobot label POS untuk *noun*, *verb*, *adverb*, *other* secara berturut-turut adalah 1, 0.75, 0.5, 0.25.
2. Berdasarkan evaluasi ROUGE-1, ROUGE-2, ROUGE-L, dan ROUGE-SU4 metode pembobotan NeFGISR mampu memberikan hasil yang lebih baik dibandingkan metode NeFTIS dengan rata-rata peningkatan nilai untuk *recall*, *precision*, dan *f-score* secara berturut-turut adalah 0.1167 (↑ 63.38%), 0.0948 (↑ 38.47%), 0.1107 (↑ 51.44%).

Adapun saran untuk pengembangan selanjutnya dari metode pembobotan NeFGISR untuk peringkasan multi-dokumen adalah:

1. Pembobotan NeFGISR belum memperhatikan homonym, hiponim, dan hipernim sehingga perlu dilakukan penelitian untuk melihat pengaruhnya terhadap metode NeFGISR.

[Halaman ini sengaja dikosongkan]

DAFTAR PUSTAKA

- Aditya, C. S. K., Fatichah, C., & Purwitasari, D. (2016). Ekstraksi trending issue dengan pendekatan distribusi kata pada pembobotan term untuk peringkasan multi-dokumen berita. *Jurnal Ilmiah Teknologi Informasi*, 14(2), 1–10. <https://doi.org/http://dx.doi.org/10.12962/j24068535.v14i2.a570>
- Arifin, A. Z., Abdullah, M. Z., & Rosyadi, A. W. (2018). Sentence Extraction Based on Sentence Distribution and Part of Speech Tagging for Multi-document Summarization. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 16(2), 843–851. <https://doi.org/10.12928/TELKOMNIKA.v16i2.8431>
- Fachrurrozi, M., Yusliani, N., & Yoanita, R. U. (2013). Frequent Term based Text Summarization for Bahasa Indonesia. *International Conference on Innovations in Engineering and Technology*, 30–32. <https://doi.org/10.15242/IEE.E1213550>
- Ferreira, R., De Souza Cabral, L., Lins, R. D., Pereira E Silva, G., Freitas, F., Cavalcanti, G. D. C., ... Favaro, L. (2013). Assessing sentence scoring techniques for extractive text summarization. *Expert Systems with Applications*, 40(14), 5755–5764. <https://doi.org/10.1016/j.eswa.2013.04.023>
- Hayatin, N., Fatichah, C., & Purwitasari, D. (2015). PENENTUAN TRENDING ISSUE DATA TWITTER MENGGUNAKAN CLUSTER IMPORTANCE UNTUK PERINGKASAN MULTI DOKUMEN BERITA. *Master's Thesis, Department of Informatics, Sepuluh Nopember Institute of Technology, Indonesia*.
- He, T., Li, F., Shao, W., Chen, J., & Ma, L. (2008). A new feature-fusion sentence selecting strategy for query-focused multi-document summarization. *Proceedings - ALPIT 2008, 7th International Conference on Advanced Language Processing and Web Information Technology*, 81–86. <https://doi.org/10.1109/ALPIT.2008.45>
- Jurafsky, D., & Martin, J. H. (2014). N-Grams. *Speech and Language Processing*,

- 2–7. Retrieved from <https://lagunita.stanford.edu/c4x/Engineering/CS-224N/asset/slp4.pdf>
- Lin, C. Y. (2004). Rouge: A package for automatic evaluation of summaries. *Proceedings of the Workshop on Text Summarization Branches out (WAS 2004)*, (1), 25–26.
- Lioma, C., & Blanco, R. (2009). Part of Speech Based Term Weighting for Information Retrieval. *Advances in Information Retrieval*, 412–423. https://doi.org/10.1007/978-3-642-00958-7_37
- Manne, S. (2012). A Feature Terms based Method for Improving Text Summarization with Supervised POS Tagging. *International Journal of Computer Applications*, 47(23), 7–14.
- Manne, S., & Fatima, S. S. (2011). Corpus based Automatic Text Summarization System with HMM Tagger. *International Journal of Soft Computing & Engineering*, 1(3), 118–123. Retrieved from http://www.ijscce.org.libproxy.lib.unc.edu/attachments/File/Vol-1_Issue-3/C073071311.pdf
- Meena, Y. K. (2014). Analysis of Sentence Scoring Methods for Extractive Automatic Text Summarization. *Italian Conference on Theoretical Computer Science*. <https://doi.org/10.1145/2677855.2677908>
- Meena, Y. K., & Gopalani, D. (2015). Evolutionary algorithms for extractive automatic text summarization. *Procedia Computer Science*, 48(C), 244–249. <https://doi.org/10.1016/j.procs.2015.04.177>
- Mei, J. P., & Chen, L. (2012). SumCR: A new subtopic-based extractive approach for text summarization. *Knowledge and Information Systems*, 31(3), 527–545. <https://doi.org/10.1007/s10115-011-0437-x>
- Pisceldo, F., Adriani, M., & Manurung, R. (2009). Probabilistic Part of Speech Tagging for Bahasa Indonesia. *Proceedings of the 3rd International MALINDO Workshop, Colocated Event ACL-IJCNLP*.
- Radev, D. R., Hovy, E., & McKeown, K. (2002). Introduction to the Special Issue on Summarization. *Computational Linguistics*, 28(4), 399–408. <https://doi.org/10.1162/089120102762671927>
- Radev, D. R., Jing, H., Styś, M., & Tam, D. (2004). Centroid-based summarization

- of multiple documents. *Information Processing and Management*, 40(6), 919–938. <https://doi.org/10.1016/j.ipm.2003.10.006>
- Rashel, F., Luthfi, A., Dinakaramani, A., & Manurung, R. (2014). Building an Indonesian rule-based part-of-speech tagger. *Proceedings of the International Conference on Asian Language Processing 2014, IALP 2014*, 70–73. <https://doi.org/10.1109/IALP.2014.6973521>
- Umam, K., Putro, F. W., Qorik, G., & Pratamasunu, O. (2015). COVERAGE, DIVERSITY, AND COHERENCE OPTIMIZATION FOR MULTI-DOCUMENT SUMMARIZATION. *Jurnal Ilmu Komputer Dan Informasi*, 1, 1–10. <https://doi.org/http://dx.doi.org/10.21609/jiki.v8i1.278>
- Verdianto, S., Arifin, A. Z., & Purwitasari, D. (2016). Strategi pemilihan kalimat pada peringkasan multi dokumen. *Nusantara Journal of Computers and Its Applications*, 2(7), 1–5.
- Wahib, A., Arifin, A. Z., & Purwitasari, D. (2015). Ekstraksi kalimat penting berbasis sebaran kalimat pada peringkasan multi- dokumen. *Master's Thesis, Department of Informatics, Sepuluh Nopember Institute of Technology, Indonesia*.
- Wan, X., Yang, J., & Xiao, J. (2007). Towards an Iterative Reinforcement Approach for Simultaneous Document Summarization and Keyword Extraction. *Annual Meeting of the Association of Computational Linguistics*, (June), 552–559.
- Xia, T., & Chai, Y. (2011). An improvement to TF-IDF: Term distribution based term weight algorithm. *Journal of Software*, 6(3), 413–420. <https://doi.org/10.4304/jsw.6.3.413-420>

[Halaman ini sengaja dikosongkan]

BIOGRAFI PENULIS



Moch Zawaruddin Abdullah lahir di Dusun Ngronggot, Desa Ngronggot, Kecamatan Ngronggot, Kabupaten Nganjuk, dan merupakan anak pertama dari tiga bersaudara dari pasangan orang tua tercinta Bapak Moch. Saeroji dan Ibu Katminingsih. Penulis telah menyelesaikan pendidikan formal di SDN 1 Ngronggot, MTsN Ngronggot, SMAN 19 Bandung. Pada tahun 2010 penulis telah menyelesaikan studi D3 Teknik Informatika sebagai Ahli Madya (A.Md.) di Politeknik Negeri Bandung (POLBAN). Pada tahun 2013 penulis menyelesaikan studi Lanjut Jenjang D4 Teknik Informatika sebagai Sarjana Sains Terapan (S.ST.) di Politeknik Elektronika Negeri Surabaya (PENS). Disamping sebagai mahasiswa S2, aktifitas keseharian penulis adalah sebagai Senior Web Developer dan konsultan IT di salah satu kampus di Surabaya. Penulis memiliki minat riset di bidang *information retrieval*, *data mining*, *text mining*, dan *image processing*.
Email korespondensi: zawaruddin017@gmail.com